

Sveučilište u Zagrebu

Grafički fakultet

Ivana Pavlović

UTJECAJ PROMJENA KANALA ZAPISA NA INTERPRETACIJU FOTOGRAFSKE SLIKE

DOKTORSKI RAD

Zagreb, 2021.



Sveučilište u Zagrebu

Grafički fakultet

Ivana Pavlović

UTJECAJ PROMJENA KANALA ZAPISA NA INTERPRETACIJU FOTOGRAFSKE SLIKE

DOKTORSKI RAD

Mentor: doc. dr. sc. Miroslav Mikota

Zagreb, 2021.



University of Zagreb

Faculty of Graphic Arts

Ivana Pavlović

IMPACT OF THE CHANNELS CHANGES ON THE INTERPRETATION OF PHOTOGRAPHIC IMAGE

DOCTORAL DISSERTATION

Supervisor: Assistant Professor Miroslav Mikota, PhD

Zagreb, 2021.

UDK 655:77:535.6

Imenovano Povjerenstvo za ocjenu doktorskoga rada:
1. prof. dr. sc. Klaudio Pap, Sveučilište u Zagrebu Grafički fakultet, predsjednik
2. prof. dr. sc. Nikola Mrvac, Sveučilište u Zagrebu Grafički fakultet, član
3. doc. art. dr. sc. Mario Periša, Sveučilište Sjever, vanjski član

Imenovano Povjerenstvo za obranu doktorskoga rada:
1. prof. dr. sc. Klaudio Pap, Sveučilište u Zagrebu Grafički fakultet, predsjednik
2. prof. dr. sc. Nikola Mrvac, Sveučilište u Zagrebu Grafički fakultet, član
3. prof. dr. sc. Mario Tomiša, Sveučilište Sjever, vanjski član
4. doc. dr. sc. Maja Rudolf, Sveučilište u Zagrebu Grafički fakultet, zamjenska članica
5. izv. prof. dr. sc. Krunoslav Hajdek, Sveučilište Sjever, vanjski zamjenski član

Mentor:
doc. dr. sc. Miroslav Mikota, Sveučilište u Zagrebu Grafički fakultet

Datum obrane doktorskoga rada: 27. rujna 2021.

Mjesto obrane doktorskoga rada: Sveučilište u Zagrebu Grafički fakultet

Povjerenstvo za obranu doktorskoga rada donijelo je sljedeću odluku:

„Obranila s ocjenom summa cum laude (*s najvećom pohvalom*) jednoglasnom odlukom Povjerenstva“

ŽIVOTOPIS MENTORA

Miroslav Mikota je rođen 4. ožujka 1967. g. u Zagrebu gdje je završio osnovnu školu, Klasičnu gimnaziju i Grafički fakaultet Sveučilišta u Zagrebu na kojem je diplomirao 1990. g., magistrirao 2005. g. te doktorirao 2007. g. Od 1990. g. radi na Grafičkom fakultetu, danas kao docent na Katedri za grafički dizajn i slikovne informacije, a od akademske godine 2016./2017. i kao prodekan za nastavu. Bio je pokretač i voditelj Katedre za primijenjenu i umjetničku fotografiju. 2011. g. je izabran u znanstveno zvanje znanstvenog suradnika, 2013. g. u naslovno zvanje profesora visoke škole, a 2015. g. u znanstveno-nastavno zvanje docent. Autor je više od 90 znanstvenih i stručnih radova, više od 400 leksikografskih članaka i većeg broja osvrta i komentara fotografskih izložbi. Kao urednik je, recenzent i autor surađivao s Maticom hrvatskom, časopisom Reporter i časopisom Grafička revija. Surađuje s Leksikografskim zavodom Miroslav Krleža kao urednik struke Tiskarstvo na projektu Hrvatske enciklopedije i Tehničkog leksikona te Likovnog leksikona kao urednik struke Fotografija. Sudjelovao je na većem broju stručnih i znanstvenih konferencija. Voditelj je organizacije Međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić te je član Znanstvenih odbora Međunarodnog znanstvenog skupa Tiskarstvo & Dizajn, Međunarodne znanstvene konferencije MATRIB, Međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić, International Conference Management of Technological Changes i International Seminar on Quality Management in Higher Education. Urednik je znanstvenih knjiga i zbornika radova i sažetaka sa znanstvenih skupova te znanstvenog časopisa Acta Graphica. Objavio je knjigu Kreacija fotografijom i dvije skripte. Autor je i izvođač više programa kolegija dodiplomskih, preddiplomskih, diplomskih i doktorskog studija te je recenzent jednog sveučilišnog programa preddiplomskog studija i većeg broja znanstvenih radova. Sudjelovao je u organizaciji i vođenju fotografskih tečajeva, seminara i radionica te je član i predsjednik stručnih žiria i strukovnih udruga. Objavio je preko 1000 fotografija te njima ilustrirao naslovne stranice, knjige, kataloge, kalendare, novine, časopise, razglednice, plakate i web stranice, a fotografije je izlagao na 30 izložbi. Široj je javnosti najpoznatiji po portretima hrvatskih književnika te ličnosti iz kulturnog života te HDR zimskim pejzažima.

Za moje Suryu i Sašu

ZAHVALA

Već sam bila odustala…

Vratio me onaj koji je jedini mogao, onaj koji me spojio natrag s mojim izvorom i pokazao mi ljepotu i novi početak u istoj okolini preobrazivši mene. Čista od svega, čistim pogledom jasno sam vidjela! Sve je bilo novo, a staro, sve je bilo isto, a predivno!

Zahvaljujem svom duhovnom učitelju Vishwaguru Mahamandaleshwar Paramhans Swami Maheshwaranadajiju, Swamijiju, jer mi pokazuje da su čuda moguća!

Najveću inspiraciju svakodnevno pronalazim u Tvojim riječima:

„ Be good, do good! “

„Where there is a will there is a way “

„Where there is love there is no distance “

„There is only one nation and that is humanity! “

“Health is not everything, but everything is nothing without health!”

Zahvaljujem se Miroslavu Mikoti, svojem mentoru i prijatelju, na svom vremenu, strpljenju, razumijevanju i svim učenjima, savjetima, idejama, razmišljanjima i sugestijama zadnjih dvadeset godina. Ovaj put u umjetničkom i znanstvenom radu započela sam zahvaljujući Tebi!

Zahvaljujem se svojim dragim kolegama i kolegicama, bivšim i sadašnjim, asistentima, docentima, profesorima i profesoricama na izdvojenom vremenu (samo za ispunjavanje ankete trebalo je izdvojiti par sati po anketi!!), sugestijama i pomoći kod izrade ovog doktorskog rada, ali i tijekom svih zajedničkih godina. Svi ste doprinijeli njegovoj izradi. Bez svih Vas, ovo ne bi bilo moguće!

Jelena Radić, hvala ti na neiscrpnoj i nesebičnoj podršci, tebe sam najmanje znala, a odigrala si u meni važnim trenutcima ključnu ulogu!

Hvala Vam svima od srca što ste bili uz mene i jeste sve ove godine!

Također se zahvaljujem svojim studentima na svemu što sam naučila i što neprestano učim od Vas!

Posebno se zahvaljujem:

- *mom pokojnom ocu što mi je svojim primjerom pokazao što su to nesebičnost, sloboda, bezuvjetna ljubav, radost i davanje u tom kratkom, ali neprocjenjivom vremenu koje smo imali zajedno.*
- *mojoj majci Vilmi što me naučila što su to vjera, rad, upornost, izdržljivost, snaga, borbenost, ali i snalažljivost, prilagodljivost, prihvaćanje, bezuvjetna ljubav i nježnost. Mama, hvala ti na svakom skuhanom ručku! Prefini su uvijek bili i uvijek će biti! Uvijek je samo jedna i jedina - mama!*
- *mom ocu, Marcelu, koji me prihvatio kao svoju i kroz toliko ljubavi odgajao da nikad nije radio razliku između mene i Luke. Hvala ti na svakoj šetnji na koju si me vodio i na svakom odlasku u grad i na svakoj šetnji na koju sad vodiš svog unuka Suryu! Neprocjenjive su! Ne znam nikoga tko se pretvori u takvu ljubav i iskonsku sreću kad ugleda dječje lice kao ti! Hvala ti na tome! Hvala ti na tvojim zafrkancijama i humoru kojim nasmijavaš cijelu obitelj, prijatelje i sve koji te znaju! Pravi si unikat!*
- *Mom bratu Luki što smo oduvijek bili prijatelji i podrška jedno drugome! Neprocjenjivo iskustvo je imati tako divnog brata! I uju!* 😊
- *Hvala mojoj obitelji s Giznika! Neiscrpan ste izvor potpore, podrške, ljubavi i inspiracije od kad sam postala igrom sudbine dio Vaše obitelji! Kroz gubitak dobiti*

takav dar je neprocjenjivo! Hvala pokojnoj teti Nadi, na tolikoj mudrosti i ljubavi, miru i staloženosti koji je uvijek dijelila sa mnom!

Obitelji moja hvala Vam na svim učenjima, na svim lijepim riječima, bezuvjetnoj podršci, vjerovanju u mene i apsolutno svemu! Znam koliko ljubavi kroz vaše postupke dolazi do mene svakodnevno! Bez Vas ne bi bilo ni mene ni svega ovog! Volim Vas! Hvala Vam! Hvala Vam na svakom trenutku!

Hvala mojim tetama na apsolutno svemu, bez Vas moj bi život bio potpuno drugačije obojan!

Hvala mojoj bližoj i daljoj rodbini i svima koji su na bilo koji način dotaknuli moj život!

Hvala svim mojim prijateljicama! Neizdrživo činite normalnim, a sreću činite još većom! Vaša ljubav i potpora su nezamjenjive!

Hvala svim mojim prijateljima! Savjet iz muške perspektive daje nove uvide!

Prijatelji moji hvala vam na svemu!

Hvala mom Saši jer je i dalje tu uz sve moje mene, a samo on zna koliko to nije lako! Dani smo jedno drugom za rast i za ljubav i ma koliko velik izazov ponekad bio, toliko je velika nagrada kad ga zajedno prođemo. Hvala što znamo da je svaki novi trenutak pred nama novo iskustvo na ovom putu. <3

I za kraj hvala mom Suryi. Naučio si me toliko puno od kad si došao u toliko malo vremena da me taj pojam novog života koji nam je dan na čuvanje apsolutno fascinira. Želim da znaš, da sam ponosna na to kako si divan čovjek, osoba, duša jer se to vidi već sada! Hvala ti što si došao u moj život i obojio ga potpuno novim bojama!

Želim da znaš uvijek i u svakom trenutku da te mama uvijek voli! I da sve možeš! I da nitko nije bolji od tebe niti si ti bolji od ikog! I sine, sve prođe, uvijek se sjeti toga! Želim ti predivan život i sve najbolje na svijetu i da svoju obitelj ako ju odlučiš imati uvijek voliš, i nosiš, s ljubavlju!

Rasti, samo rasti, gledaj uvijek naprijed! I, uvijek ustani! Nije bitno koliko puta padneš nego koliko se puta digneš! Budi svoj!

I svi ovi pridjevi moj, moja, moje, moji, svi smo mi zapravo svoji i Božji dok nam se životi isprepliću na istom putu, ruku pod ruku, stoga hvala dragom Bogu, za mene si od kad znam za sebe bio jedan i jedini, čista iskonska ljubav bez obzira na kojem kontinentu i u kojem obliku! I hvala mojoj majci što to razumije!

SAŽETAK

Uloga fotografske slike je privlačenje pažnje i, posebno kod promotivne primijenjene fotografije, prijenos informacije. Zbog svoje reproducibilnosti u tiskanim i elektronskim medijima i ikoničkog karaktera fotografije kao medija, ali i konkretne fotografske slike, tj. karaktera slikovne informacije kojoj konzumenti vjeruju, fotografska slika je najčešći dvodimenzionalni statični medij prijenosa informacija slikom. Digitalni zapis fotografske slike se sastoji od plavog, zelenog i crvenog kanala zapisa. Promjenama vrijednosti kanala se može utjecati na sintaktička i semantička svojstva, odnosno na percepciju, a time i interpretaciju fotografske slike.

Kroz disertaciju se definiraju granice promjena plavog, zelenog i crvenog kanala digitalnog zapisa unutar kojih se zadržava ikonički karakter fotografske slike te se unutar tih granica određuju promjene vrijednosti pojedinog kanala kojima se ciljano utječe na njenu percepciju i interpretaciju u uvjetima optimalne i metamerijske konzumacije.

Istraživanje se temelji na vizualnim procjenama ispitanika i primjeni mjernih metoda. Vizualne se procjene provode temeljem fotografskih slika realiziranih na kalibriranim izlaznim jedinicama u standardnim uvjetima promatranja (ISO 3664 : 2009). Za potrebe se istraživanja snimaju testne fotografije odabranih motiva i sintaktičkih postavki. Tako se dobiveni digitalni zapisi učitavaju u program za obradu te se, kao i standardna tablica boja, obrađuju promjenama vrijednosti plavog, zelenog i crvenog kanala. Za dobivene se digitalne zapise u istom programu određuju L, a i b vrijednosti boja iz kojih se računaju ukupne razlike boja te se analiziraju histogrami fotografskih slika.

Temeljem provedenih istraživanja potvrđeno je da se promjenama vrijednosti R; G i B kanala digitalnog zapisa fotografske slike u definiranim granicama zadržava njezin ikonički karakter uz utjecaj na percepciju i interpretaciju te slike, da te granice ovise o motivu i sintaktičkim postavkama fotografske slike te da je promjenama vrijednosti kanala zapisa unutar zadržavanja ikoničnosti moguće optimizirati fotografsku sliku za uvjete konzumacije.

Ključne riječi: fotografija, percepcija, crveni (R), zeleni (G), plavi (B) kanali, male promjene kod crvenog (R), zelenog (G), plavog (B) kanala, portretna fotografija, fotografija pejzaža, fotografija hrane

EXTENDED ABSTRACT

The role of the photographic image is to attract attention, and especially in the field of applied promotion photography transferring information. Due to its reproducibility in print and electronic media, and the iconic character of a photograph as the medium but also the specific photographic image, ie. image information which consumers find trustworthy, the photographic image is the most commonly occurring static two-dimensional medium for image information transfer.

A digital record of photographic image consists of blue, green, and red channels. Changes in the value of the channel can influence syntactic and semantic properties as well as the perception, hence the interpretation of the photographic image in general.

Throughout the thesis, the deviation limits of blue, green and red channels of the digital recorded image within which the iconic character of the photographic image is retained are defined. Within these limits the values of a single channel which targetly influences its perception and interpretation in terms of optimal and metameric consumption are determined.

The research is based on visual assessments of the respondents, and the application of measurement methods. Visual assessments are performed on the basis of photographic images realized on calibrated output units under standard observation conditions (ISO 3664: 2009). For research purposes three test photographies of selected motifs and syntactic settings are taken. The digital records obtained are loaded into the processing program, and same as the standard color table are processed by changes of blue, green, and red channels. Using the same program for obtained digital records L*, a*, and b* values of colors are determined, from which the total color differences are calculated, and histograms of photographic images are described

Visual assessments are carried out by experts in the field of applied photography, and respondents without any such direct experience but with an interest in visual communications and photography.

Since the digital record of the photographic image consists of a blue, green, and red channels, color changes can be targeted at the stage of processing the digital image record by changing each channel. By changing the channel i.e., by amplifying or weakening it to a certain percent, the photographic image still retains its iconicity though its interpretation changes. This way the photographic image is consumed under different conditions i.e., its optimal interpretation and perception can also be influenced under metameric conditions.

Three thematically different motifs were used in the dissertation, from which three different examples were taken for portraits, processed with and without selection of a particular part of the photo, a total of 6 photographs. For the photo of the landscape, three examples of photographs processed without selection on the entire surface of the image were taken, and for the photo of the food three examples were taken, one of which was processed with selection and without, one separately without selection and one separately with selection. After amplifying and weakening each channel separately of each individual photo, a total of 13, each photo had 24 variations alongside the original photo which was the first phase of the work. After the realization of test images, photographs were further implemented through the following six phases: the selection of test photographic images, the selection of test photographic images that meet the condition of retaining iconicity, the assessment of the interpretation of test photographic images, the retention of the iconic photographic images in the metameric conditions of consumption, measuring tests and determining the correlation between the change in perception and interpretation by changing the value of the channels.

Based on the conducted research, it has been confirmed that changes in the value of red, green, and blue channels of the photographic image digital record retain their iconic character within the defined boundaries, with the influence on the image perception and interpretation. Moreover, it has been confirmed that these boundaries depend on the motif and syntactic settings of the photographic image, and that with the changes in the value of red, green and blue channels one can optimise the photographic image for the conditions of consumption, while retaining the photograph iconicity.

Keywords: photography, perception, red (R), green (G), blur (B) channels, small changes in red (R), green (G), blue (B) channels, portrait photography, landscape photography, food photography

Sadržaj

1. UVOD 1

1.1. Obrazloženje teme i dosadašnja istraživanja 1

1.2. Cilj i hipoteze istraživanja 5

1.3. Očekivani znanstveni doprinos 5

2. TEORIJSKI DIO 6

2.1. Boja sa psihofizičkog i fizikalnog aspekta 6

2.1.1. Sustavi za prikaz boja 9

2.1.2. Kolorimetrija i mjerenje boja 18

2.2. Tehnike vizualnog ocjenjivanja fotografske slike 19

2.3. Sintaksa i semantika fotografske slike 20

2.3.1. Sintaksa fotografske slike 20

2.3.2. Semantika fotografske slike 28

2.4. Fotografski motivi 29

2.4.1. Portret 29

2.4.2. Pejzaž 30

2.4.3. Fotografija hrane 32

2.5. Digitalni fotografski sustav 34

2.6. Histogram digitalnog zapisa fotografske slike 42

3. EKSPERIMETALNI DIO 45

3.1. Metodologija i plan istraživanja 45

3.2. Prva faza: Realizacija testnih fotografskih slika 49

3.2.1. Portret 49

3.2.2. Pejzaž 52

3.2.3. Fotografija hrane 54

3.3. Druga faza: Odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera 55

3.4. Treća faza-stupanj suglasnosti prigodnog uzorka ispitanika s izborom ekspertne skupine 65

3.5. Četvrta faza – zadržavanje ikoničnosti fotografskih slika u metamerijskim uvjetima konzumiranja 67

3.6. Peta faza- mjerno određivanje promjena boja 70

3.7. Šesta faza 71

3.8. Opis uzorka ispitanika 72

4. REZULTATI I RASPRAVA 73
4.1. Odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera 73
4.2. Utvrđivanje korelacije promjene percepcije i interpretacije promjenom vrijednosti kanala zapisa 77
4.2.1. Procjene prikupljene u trećoj fazi istraživanja - Likertova skala, Spearmanov koeficijent i dvosmjerna 3x4 ANOVA 77
4.2.1.1. PORTRET BEZ SELEKCIJE 80
4.2.1.2. PORTRET SA SELEKCIJOM 82
4.2.1.3. PEJZAŽ 85
4.2.1.4. HRANA BEZ SELEKCIJE 88
4.2.1.5. HRANA SA SELEKCIJOM 90
4.2.2. Procjene prikupljene u trećoj fazi istraživanja - subjektivna procjena - odabir fotografskih slika temeljem traženih atributivnih karakteristika 92
4.2.3. Procjene prikupljene u četvrtoj fazi istraživanja – metamerija 100
4.2.3.1. Rangiranje uzoraka prema kriteriju sličnosti s originalom 100
4.2.3.2. Odabir najprivlačnijih uzoraka za svaki od tri setova fotografija – portret, pejzaž, fotografija hrane 101
4.2.3.2.1. DAYLIGHT izvor svjetla 103
4.2.3.2.2. STORELIGHT izvor svjetla 106
4.2.3.2.3. HOMELIGHT izvor svjetla 108
4.3. Mjerna ispitivanja 111
4.3.1. Mjerno određivanje promjene boja testnih fotografskih slika odabranih u drugoj fazi istraživanja i ukupne vrijednosti promjene cijele površine tablice boja 111
4.3.2. Mjerno određivanje promjene boja pojedinih odabranih boja standardne tablice boja 122
4.3.3. Histogrami fotografskih slika 131
5. ZAKLJUČAK 145
6. LITERATURA 152
7. PRILOZI 157
7.1.1. PRILOG 1 -POPIS SLIKA 157
7.1.2. PRILOG 2 - POPIS TABLICA 162
8. ŽIVOTOPIS 166
8.1. Popis objavljenih radova 170

1. UVOD

1.1. Obrazloženje teme i dosadašnja istraživanja

Fotografija je najzastupljeniji medij dvodimenzionalne statične slike koji se kao nositelj informacije realizira kroz tiskane i sve više kroz elektronske medije. Razlog tome je i u tehničkim karakteristikama fotografije kao medija, ali i u njenim semantičkim svojstvima. Fotografska slika gotovo je neizostavan dio informacije korišten kroz različite medije što pokazuje njen iznimno visoki stupanj reproducibilnosti. S tehničke strane gledano, kao medij, fotografija je slika indeksičnog karaktera koja nastaje kao posljedica djelovanja svjetla na senzor - fotoosjetljivi medij u digitalnom fotografskom sustavu – čime nastaje njezin digitalni zapis u plavom, zelenom i crvenom kanalu koji zajedno čine cjelokupni prikaz digitalne slike. (Slika 1) S obzirom na to da je scena u pravilu trodimenzionalna, a fotografska slika dvodimenzionalna, te da pri realizaciji fotografske slike u odnosu na snimanu scenu nastaje i niz drugih promjena, fotografija kao medij ima i određeni stupanj simboličkog karaktera, ali se primarno doživljava ikonički što znači da joj konzument vjeruje više nego drugim medijima slikovnog prenošenja informacija. [1][2][3][4][5]

Osim promatranja fotografije kao medija, svaka se fotografska slika sa semantičkog stanovišta može promatrati i pojedinačno. Indeksičnu fotografsku sliku karakterizira da ne prikazuje izravno objekt, već posljedicu njegovog djelovanja, simbolička prenosi informaciju temeljem prethodnog iskustva ili konteksta i također direktno ne prikazuje objekt, a ikonička, unutar karakteristika medija, realno prikazuje objekt. Bez obzira koji je semantički karakter konkretne fotografske slike, da bi prenijela informaciju uz što manji komunikacijski šum, tj. da bi ju konzument ispravno percipirao i interpretirao, ona mora zadržati i ikonički karakter. [1][3][6][7]

U ovoj se disertaciji analizira utjecaj promjena boja do zadržavanja ikoničkog karaktera na percepciju i interpretaciju fotografske slike. Boja je jedan od najvažnijih elemenata fotografske sintakse [8][9], a na nju se tehnički utječe kroz sve faze fotografskog, ili krosmedijskog, sustava – od snimanja, preko obrade digitalnog zapisa do njegove realizacije. [10][11] Boje bitno utječu na percepciju što omogućuje i upravljanje percepcijom i interpretacijom promjenama boja fotografske slike. [12][13][14][15]

Kako se digitalni zapis fotografske slike sastoji od plavog, zelenog i crvenog kanala, promjene boja je moguće ciljano provesti u fazi obrade digitalnog zapisa promjenama pojedinog kanala. Promjenom kanala, tj. njegovim pojačavanjem ili oslabljivanjem do određenog postotka, fotografska slika i dalje zadržava svoju ikoničnost, ali se njena interpretacija mijenja. [16][17][18][19] Na ovaj se način može utjecati i na fotografsku sliku koja se konzumira u različitim uvjetima, tj. može se utjecati na optimalnu percepciju i interpretaciju fotografske slike u metamerijskim uvjetima konzumacije.


a)


b)


c)


d)

Slika 1 Prikaz originala (a) te plavog (b), zelenog (c) i crvenog (d) kanala digitalnog zapisa slike

zapisa fotografske slike u granicama zadržavanja ikoničkog karaktera analizirane u ovoj disertaciji.

Do sada provedena ispitivanja u području upravljanja percepcijom i interpretacijom fotografske slike promjenama vrijednosti plavog zelenog i crvenog kanala digitalnog zapisa, uz zadržavanje ikoničkog karaktera su prvenstveno provedena u području portretne fotografije. Pri tome je zadržavanje ikoničkog karaktera kod portretne fotografije dovedeno u vezu s granicama ukupne promjene standardnih boja kože. Rezultati ispitivanja su ukazali kako se time potencijalno omogućuje manipulacija efektom što može biti iskorišteno u različitim područjima primijenjene fotografije, pogotovo one promotivnog karaktera. Pokazano je kako se takve promjene mogu provesti kroz sve faze digitalnog fotografskog sustava, ali i da se maksimalna kontrola efekta postiže u fazi obrade digitalnog zapisa fotografske slike kada je moguće direktno djelovanje na pojedini kanal zapisa uz zadržavanje vrijednosti ostalih kanala konstantnim. Dosadašnja ispitivanja ukazuju kako je optimalni regulator percepcije i interpretacije portretne fotografije u fazi obrade digitalnog zapisa regulacija pojačavanjem i oslabljivanjem crvenog kanala unutar granica +/- 6%. [6][21][22]

S obzirom na sintaktička svojstva portretne fotografije, tj. u tehničkom smislu mogućnost izdvajanja i selektiranja lica, a time i površine fotografske slike karakterizirane bojom lica odnosno kože, u fazi obrade je kod portretne fotografije moguće i ciljano mijenjanje vrijednosti kanala zapisa za boje kože uz zadržavanje neizmijenjenih informacija o bojama preostalog dijela motiva što povećava zadržavanje ikoničkog karaktera konkretne fotografske slike uz upravljanje percepcijom i interpretacijom fotografije. [6][21]

Ovakav je pristup moguć i kod ostalih promatranih motiva kod kojih je realizacija sintaktički temeljena na izdvojenoj boji ili omogućuje selekciju površine karakterističnih ciljanih boja kojima se, uz zadržavanje ikoničkog karaktera, upravlja percepcijom i interpretacijom fotografije. [23] Kod fotografskih slika kod kojih je realizacija sintaktički temeljena na prevladavajućoj boji, utjecaj na vrijednosti kanala zapisa se isključivo provodi na cijeloj površini.

Provedena ispitivanja na fotografijama hrane također ukazuju na mogućnost upravljanja percepcijom i interpretacijom promjenama vrijednosti plavog, zelenog i crvenog kanala uz zadržavanje ikoničkog karaktera konkretne fotografije. Ispitivanja su provedena uz promjene vrijednosti kanala +/- 9%, a rezultati ukazuju na ovisnost efekta o karakteristikama boja konkretnog motiva ili dijela motiva [23]. Utvrđen je i utjecaj malih promjena boja, unutar prihvatljivosti, prema kriteriju utvrđivanja ukupne razlike boja ($\Delta E00$) na percepciju pejzažne fotografije kao i na fotografije drugih fotografskih motiva [24][25].

Dio provedenih ispitivanja je usmjeren i objektivizaciji i kvantifikaciji promjena fotografske slike dobivenih promjenama kanala zapisa. Glavnina je mjernih analiza usmjerena određivanju ukupne razlike boja (ΔE00) za primarne boje aditivne i suptraktivne sinteze, standardne boje realnih fotografskih motiva, odabrane karakteristične boje konkretne fotografske slike i akromatske boje [26]. Dio je ispitivanja usmjeren i strukturalnim promjenama fotografske slike te analizi promjena histograma zapisa cijele površine fotografske slike ili odabrane selekcije [27].

Dosadašnja ispitivanja ukazuju na mogućnost upravljanja percepcijom i interpretacijom fotografskom slikom promjenama vrijednosti kanala digitalnog zapisa fotografske slike uz zadržavanje ikoničkog karaktera te slike. Granice promjena te odabir kanala su ovisni o odabranom motivu, sintaktičkim karakteristikama i uvjetima promatranja fotografske slike.

1.2. Cilj i hipoteze istraživanja

Cilj doktorske disertacije je definirati granice promjena plavog, zelenog i crvenog kanala digitalnog zapisa odabranog fotografskog motiva unutar kojih se zadržava ikonički karakter fotografske slike i ciljano utječe na njezinu percepciju i interpretaciju u uvjetima optimalne i metamerijske konzumacije.

Hipoteze:

H1: Promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa u definiranim granicama se zadržava ikonički karakter fotografske slike uz utjecaj na njenu percepciju i interpretaciju.

H2: Granice promjene vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa u granicama zadržavanja ikoničkog karaktera ovise o motivu i sintaktičkim postavkama fotografske slike.

H3: Promjene vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa u granicama zadržavanja ikoničkog karaktera omogućuju ciljanu interpretaciju fotografske slike u uvjetima metamerijske konzumacije.

1.3. Očekivani znanstveni doprinos

Očekivani znanstveni doprinos sastoji se od nekoliko tvrdnji koje će proizaći iz hipoteza ove doktorske disertacije, a to su:

1. definiranje granica promjena vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa uz zadržavanje ikoničkog karaktera fotografskih slika konkretnih motiva i sintaktičkih postavki.

2. Određivanje optimalnih promjena vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa za upravljanje interpretacijom fotografske slike određenog motiva i sintaktičkih postavki u uvjetima optimalne i metamerijske konzumacije.

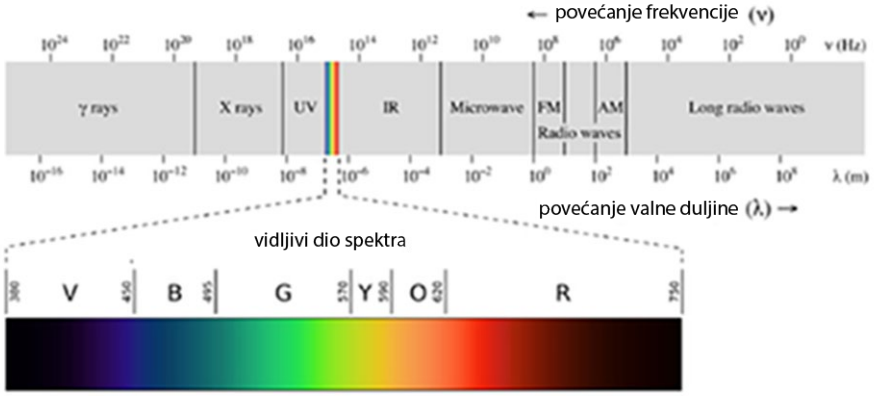
3. Utvrđivanje korelacije promjena vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa u granicama zadržavanja ikoničkog karaktera i percepcije i interpretacije konkretne fotografske slike.

2. TEORIJSKI DIO

2.1. Boja sa psihofizičkog i fizikalnog aspekta

Kada izvor svjetla osvijetli neki objekt informacija o tom objektu ulazi u oko čovjeka iz kojeg informacija dalje putuje do mozga gdje se odvija doživljaj boje u centru za vid. Kod osvijetljenog objekta mogu se mjeriti spektralne karakteristike svjetla i objekta, apsorpcija, refleksija i transmisija što spada pod dio fizike. U ljudskom oku građa samog oka, štapići i čunjići primaju informaciju o tome što vide što spada pod fiziologiju, dok sam doživljaj boje spada pod psihologiju i različit je od osobe do osobe, a odvija se u centru za vid u mozgu. Građa ljudskog oka te štapići i čunjići utječu na to kakvu informaciju oko šalje dalje do centra za vid. Sam doživljaj boje ovisi o spektralnom sastavu svjetla koje pada na promatrani predmet, o molekularnoj strukturi materijala s kojeg se svjetlo propušta ili reflektira i o osjetu boje kod čovjeka preko njegovog vidnog sustava i mozga.

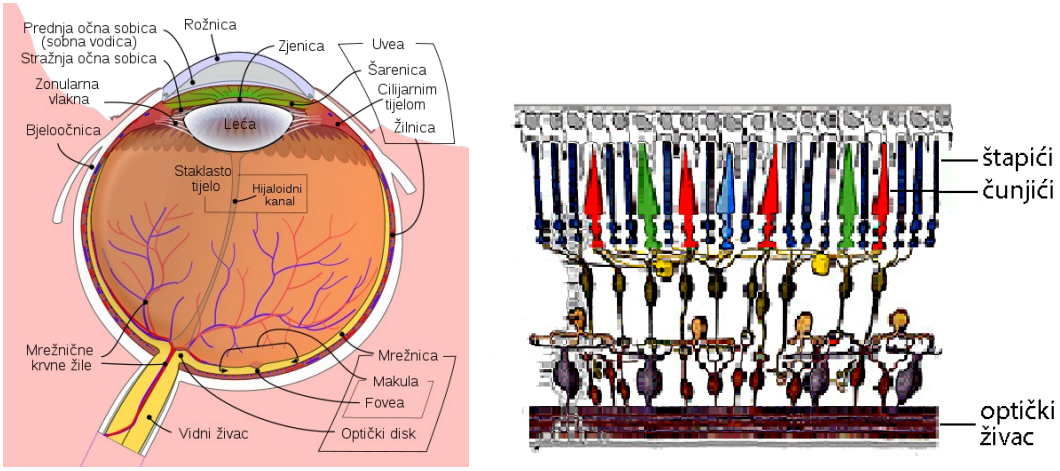
Sunce kao primarni i najveći izvor svjetlosti (svijetli sam od sebe) emitira elektromagnetsko zračenje različitih valnih duljina od čega je samo jedan manji dio vidljiv ljudskom oku, tzv. vidljivi dio spektra (ili bijelo svijetlo) valnih duljina od cca 380 do 750nm. (Slika 2). [28]



Slika 2 Spektar elektromagnetskih valova s istaknutim dijelom vidljive svjetlosti [28]

U mrežnici ljudskog oka nalaze se dvije vrste receptora odgovorne za osjet boje - čunjići i svjetline -štapići (Slika 3). Čunjića ima oko 6-7 milijuna i rade pod jakim svjetlom, dok štapića ima oko 118 milijuna. Svaki čunjić ima svoj odvodni živac te se mogu promatrati kao odvojeni, ali preklapajući filmovi u boji koji djeluju kao najmanja vidna stanica, dok štapiće možemo

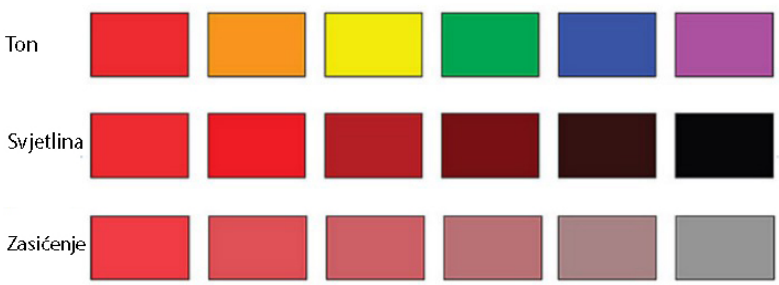
promatrati kao vrlo brzi crno-bijeli film. Vezivnim tkivom povezane su s bipolarnim pa ganglioniranim stanicama koje vidnom živcu daju vlakna.[29] [30]
Razlikuju se tri vrste čunjića, oni najviše osjetljivi na plavi dio spektra (od 420nm do 440nm), oni koji najviše apsorbiraju zeleni dio spektra (530-540nm) i oni koji najviše apsorbiraju crveni dio spektra (od 560 nm do 580nm). [31]



Slika 3 Shematski presjek građe ljudskog oka [29] *te prikaz štapića i čunjića [30]*

Boja je stvar subjektivne interpretacije i percepcije, a definiraju je ton, zasićenje i svjetlina koji spadaju u psihofizičke karakteristike boje (ono što promatrač osjeća), dok su fizikalne karakteristike (ono što izmjeri neki uređaj) dominantna valna duljina, čistoća pobude i luminacija.

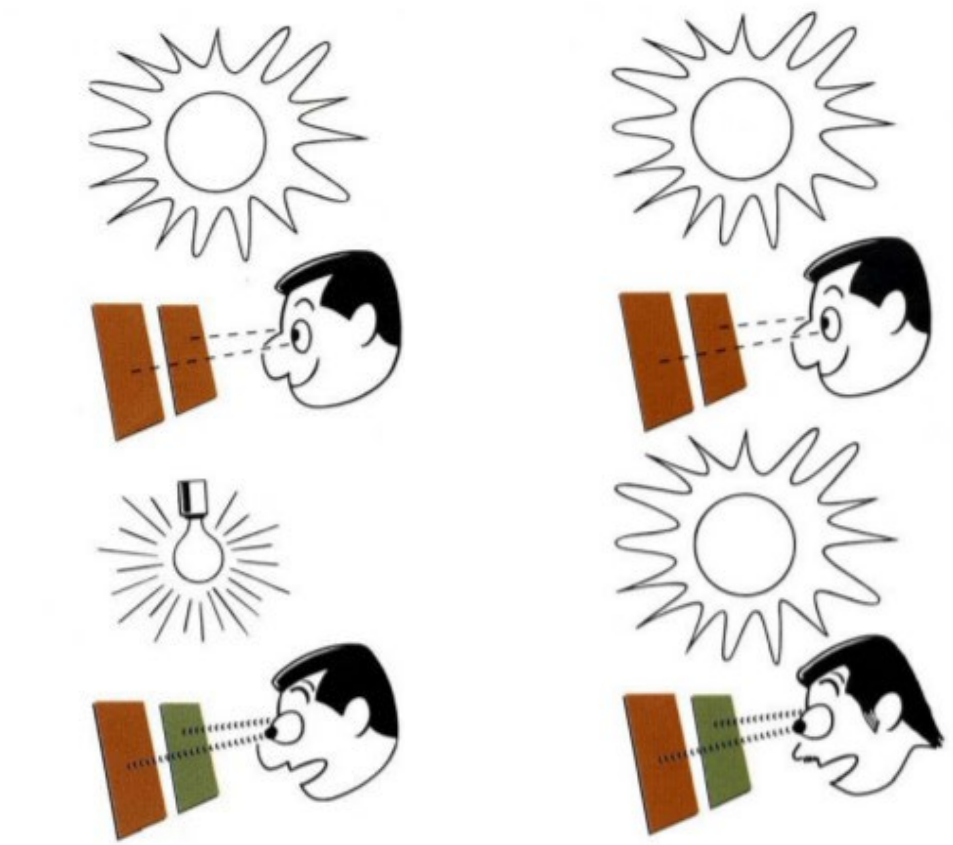
Ton boje označuje da se govori o npr. crvenoj, zelenoj ili plavoj boji što ovisi o dominantnoj valnoj duljini boje. Svjetlina definira kojoj akromatskoj točki – crnoj ili bijeloj je boja bliža. Ako je bliža crnoj točki, boja će biti tamnija, a ako je bliža bijeloj točki, boja će biti svjetlija. Treća karakteristika boje, zasićenje, govori koliko je boja „čista“. To znači ako se boji dodaje bilo koji ton sive od bijele do crne boja je manje zasićena. Kromatičnost boje određuju ton i zasićenje boje, a svjetlina boje ne utječe na nju. (Slika 4)



Slika 4 Prikaz tona, svjetline i zasićenja boje

Kada dvije boje ostvaruju iste stimuluse pod određenim uvjetima, a različite pod nekim drugim pojavljuje se **metamerija**, odnosno dva izvora svjetla koja su sastavljena od različitih mješavina različitih valnih duljina mogu imati jednak oblik pojavljivanja boje koji se naziva metamerizam. Dva izvora svjetla imaju jednake tropodražajne vrijednosti neovisno o tome iz koje spektralne kompozicije proizlaze.[31]

Metamerizam se javlja u četiri oblika pa tako se govori o metamerizmu izazvanom vrstom svjetlosti, metamerizmu izazvanom promatračem, metamerizmu izazvanom veličinom polja te metamerizmu koji se pojavljuje promjenom geometrije promatranja uzorka (Slika 5). Krivulja spektralne refleksije dva uzroka koji međusobno stvaraju metamerne stimuluse boja mora imati iste vrijednosti kod najmanje tri različite valne duljine vidljivog dijela spektra. [32]



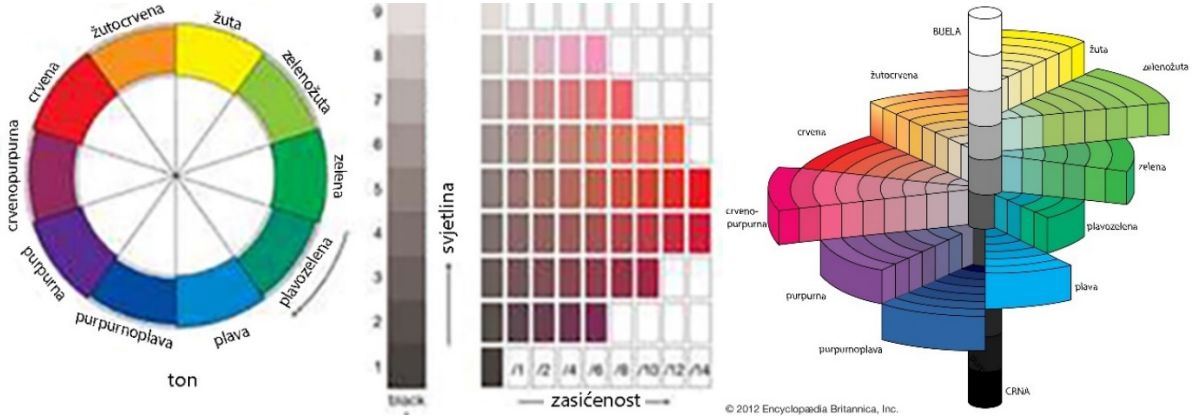
a) b)

Slika 5 Primjer metamerije: a) izazvane izvorom svjetla i b) izazvane promatračem [32]

2.1.1. Sustavi za prikaz boja

Sustavi za prikaz boja nastali su iz potrebe za objektivnom i sustavnom klasifikacijom boja svih boja spektra te vrednovanjem odnosa među bojama. Osnovnu podjelu čine sustavi bazirani na psihološkim atributima boje, tzv. prirodni (intuitivni) modeli gdje spadaju Munsellov sustav boja i Natural Colour System-NCS, zatim sustavi bazirani na miješanju boje svjetla i pigmenta gdje spadaju Ostwaldov sustav i Panotone sustav te na objektivne sustave bazirane na CIE zakonitostima gdje spadaju CIE XYZ, CIE LAB i CIE LUV.[33]

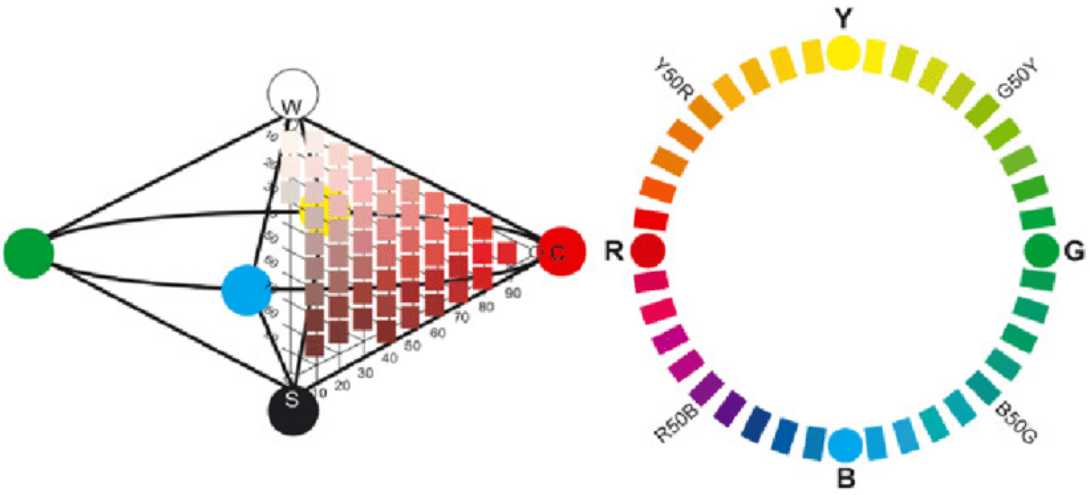
Munsellov sustav boja (HVC) nastao je 1905. godine, a prikazuje ton (H-hue), svjetlinu (V-value) i zasićenost boje (C- chroma) prema njihovim valnim duljinama. Postavio ga je slikar A. H. Munsell. Munsell je definirao 10 osnovnih tonova boje: crveni, žutocrveni, žuti, zelenožuti, zeleni, plavozeleni, plavi, purpurnoplavi, purpurni i crvenopurpurni. Munsellov kolor sustav nekad se naziva i Munsellovo drvo boja i atlas boja. Uzorci u svakom redu bez obzira na boju imaju jednaku svjetlinu, a u svakom stupcu jednako zasićenje. Ovaj sustav primjenjuje se i danas, ali se u ocjeni boja na fotografiji danas ne koristi (Slika 6). [34]



Slika 6 Munsellov kolor sustav [34]

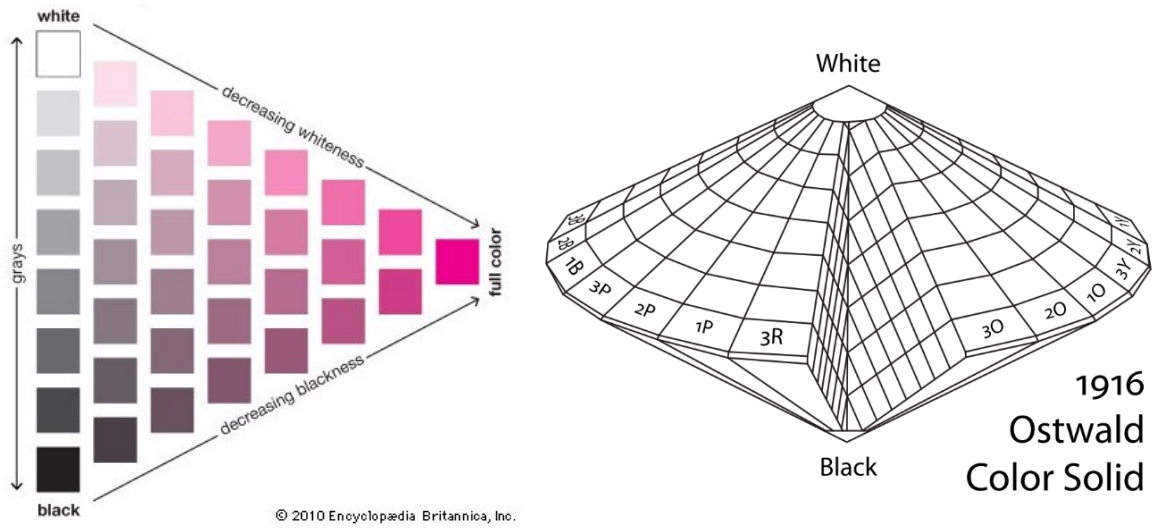
NCS (Natural Color System) sustav boja kakav danas znamo nastao je 1920.godine. Temelji se na šest osnovnih boja od čega su dvije temeljne boje, bijela i crna te četiri nemiješane međuboje – crvena, plava, zelena i žuta, te nijansama sive od bijele do crne (Slika 7). Sustav ne poznaje miješane boje poput npr. žutocrvene i sl. Najvažnija razlika između ovog sustava i većine ostalih sustava boja leži u tome što ovaj sustav definira boju prema tome kako ih čovjek doživljava zbog čega se smatra i intuitivnim sustavom boja. Svi podaci o bojama u ovom sustavu su približni jer se definicija elemenata NCS sustava temelji na percepciji, a ne na

proizvodnji boje. Sustav definira 1750 standardnih boja u intuitivno/prirodno strukturiranom prostoru boja. [35]



Slika 7 NCS sustav boja [35]

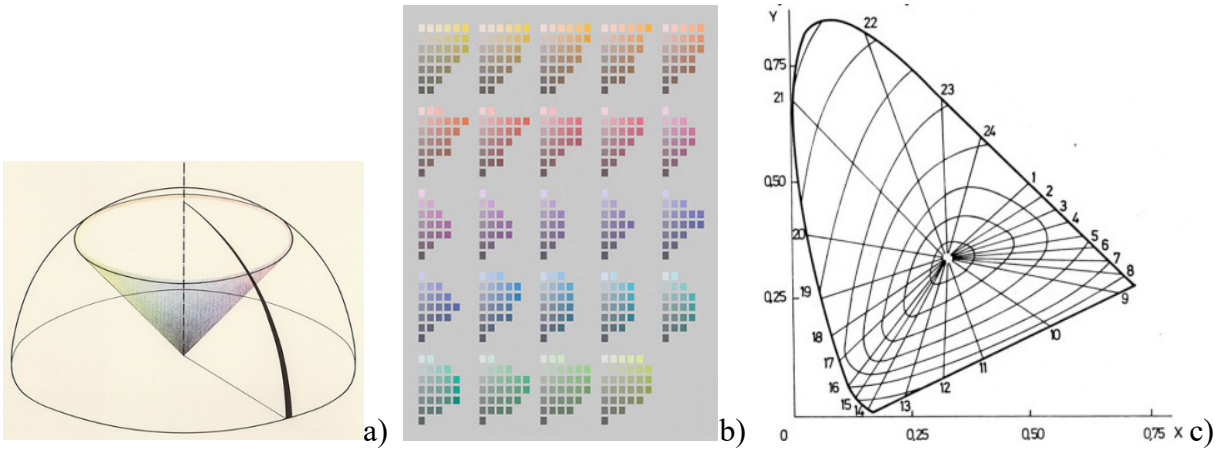
Ostwaldov sustav boja boje svrstava u trodimenzionalni oblik nalik dva stošca spojena u bazu dok je presjek kroz to tijelo jednakostranični trokut na čijim vrhovima su pozicionirane tri osnovne boje, na vrhu bijela, na dnu crna, a na trećem vrhu jedna od kromatskih boja (Slika 8). Nedostatak je bio ograničenje za broj kromatskih boja te nema jednostavan način bilježenja milijuna boja.[36]



Slika 8 Ostwaldov sustav boja [37] [36]

DIN sustav boja (DIN 6164) definirao je M. Richer. Nastao je kao potreba da se napravi jednostavniji sistem od Ostwaldovog sistema boja. Po ovom sustavu boje se definiraju kroz njihov ton (F-Farbton), zasićenje (S – Saettigung) i tamninu (D -Dunkelstufe). Zasićenje boje

opada od centra dijagrama gdje se nalazi akromatska točka prema obodu dijagrama (ovalni dijelovi unutar dijagrama predstavljaju određene vrijednosti) (Slika 9). Za razliku od svih ostalih sustava, jedino ovaj sustav definira tamninu, a ne svjetlinu. Ovaj se sustav danas rjeđe koristi, a nekad se često koristio u fotografskoj praksi. [38]



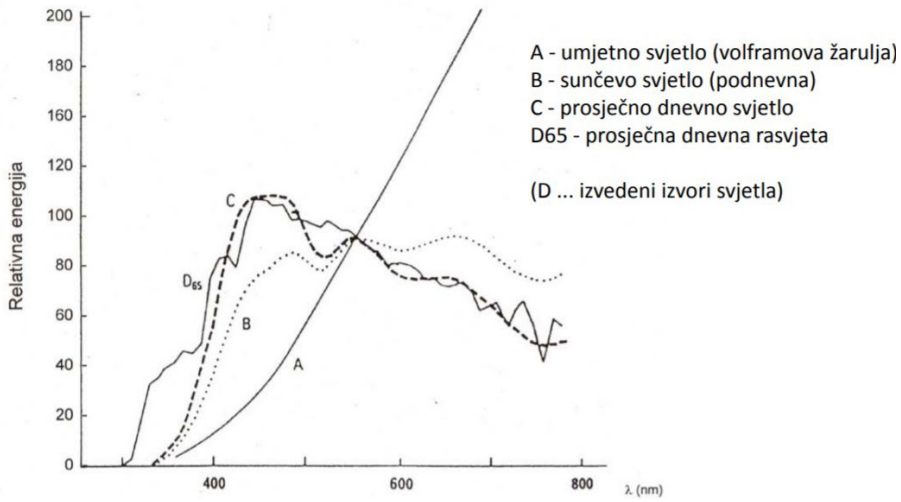
Slika 9 DIN kolor sistem, DIN kolor karta i DIN sustav boja [38]

Pantone sustav (Slika 10) u svom katalogu boja pokriva preko tisuću obojenih uzoraka koji su napravljeni iz 13 osnovnih pigmenata miješanih u određenom postotku (14 ako se računa crna). Boje su identificirane brojem koji je dobiven određenim recepturama kod proizvođača bojila. 2007. godine uveli su novi Goe System koji sadrži preko dvije tisuće novih boja u novom sistemu. Ideja Pantone sustava je da dizajnerima omogući upotrebu točnog izgleda boje u tiskanom izdanju. [39][40]



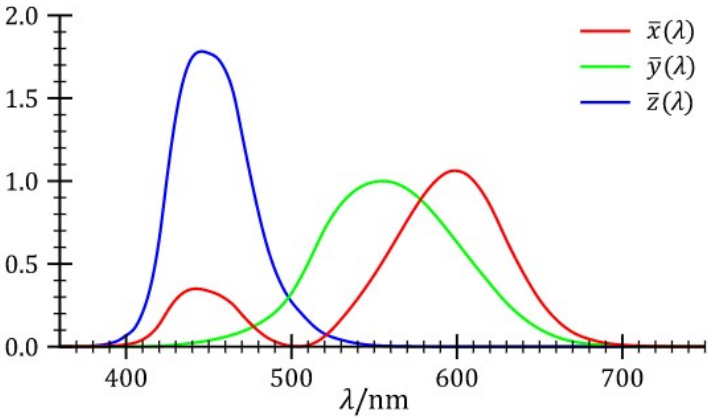
Slika 10 Primjer Pantone karte boja [39]

raspodjele energije zračenja (Slika 11), definirala je pojam „standardni promatrač“ (Slika 12) i definiran je prostor boja CIE 1931 XYZ, dijagram kromatičnosti CIE 1931. 1976. godine razvili su prostore boja CIELAB i CIELUV koji su danas u širokoj primjeni. Na temelju CIE LAB sustava razvili su forme za izračun razlike boja CIEDE94 i CIEDE2000 [41].



Slika 11 CIE standardna rasvjeta[33]

Tropodražajne vrijednosti ovise o vidnom polju promatrača, a da bi se ta varijabla eliminirala definiran je pojam standardnog promatrača. Originalno standardni promatrač pokrivao je vidni kut od 2° (vjerovalo se da su na boju osjetljivi čunjići smješteni oko 2° u fovei) pa je tako standardni promatrač poznat i kao CIE 1931 2° standardni promatrač (Slika 12). 1964. godine definiran je standardni promatrač CIE 1954 10°. Iako je suvremeniji, manje je korišten, a koristi se za vidno polje veće od onog koje pokriva vidni kut 4° [31]



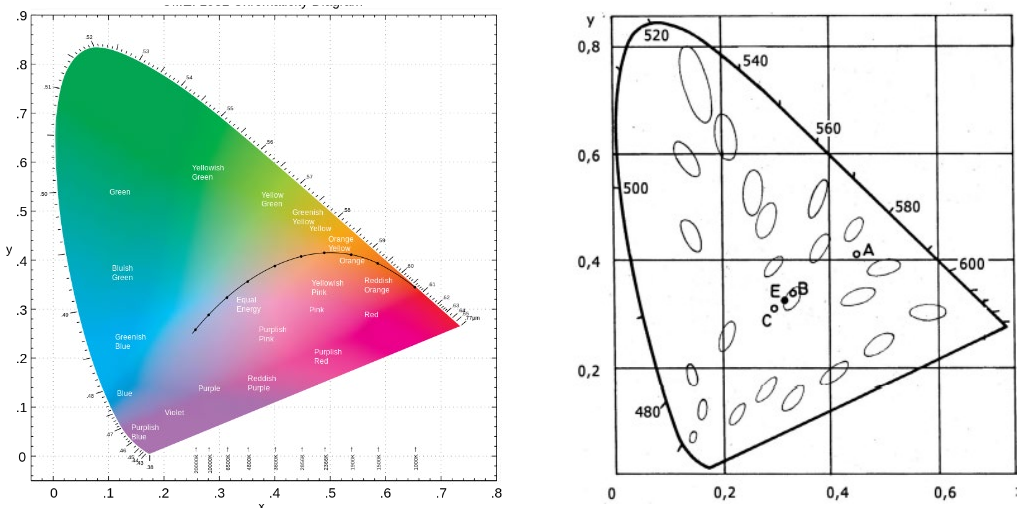
Slika 12 CIE funkcija podudarnosti standardnog promatrača [31]

Dijagram kromatičnosti CIE 1931 (Slika 13) je dobiven transformacijama trokuta boja, a temelji se na određivanju X, Y i Z -tristimulusnih vrijednosti. Te vrijednosti ovise o spektralnoj refleksiji mjerene boje, standardnom izvoru svjetla i imaginarnim distribucijskim koeficijentima koji se odnose na stimulus boje ovisno o valnoj duljini. Boje koje uz iste uvjete gledanja imaju iste tristimulusne koeficijente doživljavaju se kao iste. Iz izračunatih tristimulusnih vrijednosti izračunavaju se kromatične koordinate x, y i z prema formulama:

$x = X : (X + Y + Z)$, $y = Y : (X + Y + Z)$, $z = Z : (X + Y + Z)$. [31]

Dijeljenje sa zbrojem omogućuje definiranje kromatičnosti kroz x i y vrijednosti koje se zatim ucrtavaju u dijagram. Kako je Y vrijednost vezana uz svjetlinu odnosno luminaciju, u ovom sustavu boje se često definiraju xyY vrijednostima.

CIE 1931 dijagram kromatičnosti ima ucrtane elipse koje definiraju one razlike među bojama koje se mogu tolerirati. Nedostaci prikaza su ovisnost položaja akromatske točke ovisno o izvoru svjetla, a i površine krivulja su u različitim područjima dijagrama dosta različite. Ovaj se dijagram zadržao i danas zbog jednostavnosti i preglednosti.

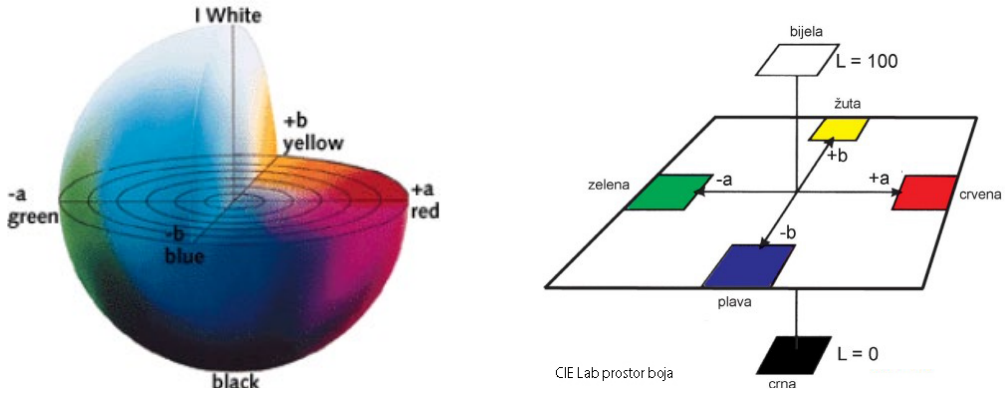


Slika 13 CIE 1931 dijagram kromatičnosti

CIE LUV sustav je danas dominantan sustav za prikaz boja monitora, TV ekrana i slično. Izrađen je 1976 godine kad i CIE Lab sustav.

CIE Lab prostor boja izradila je 1976. godine CIE komisija, a njegova skala boja prelazi modele boja RGB i CMYK. (Slika 14) Jedan od najvažnijih atributa Lab modela je neovisnost uređaja, a to znači da su boje definirane neovisno o njihovoj prirodi stvaranja ili uređaju na

kojem su prikazane. Lab prostor boja koristi se kada se grafike za ispis moraju pretvarati iz jednog prostora boja u drugi (RGB u CMYK) dok je prostor boja trodimenzionalan čiji izračun predstavlja kvadratne korijene. L, a i b vrijednosti su obično apsolutne, s unaprijed definiranim rasponom. Skraćenica L predstavlja svjetlinu, i ona ima raspon od 0, što predstavlja idealno crno do 100 što predstavlja idealno bijelo, dok a predstavlja raspon između zelene i crvene boje i b raspon između žute i ljubičastoplave boje. [42]

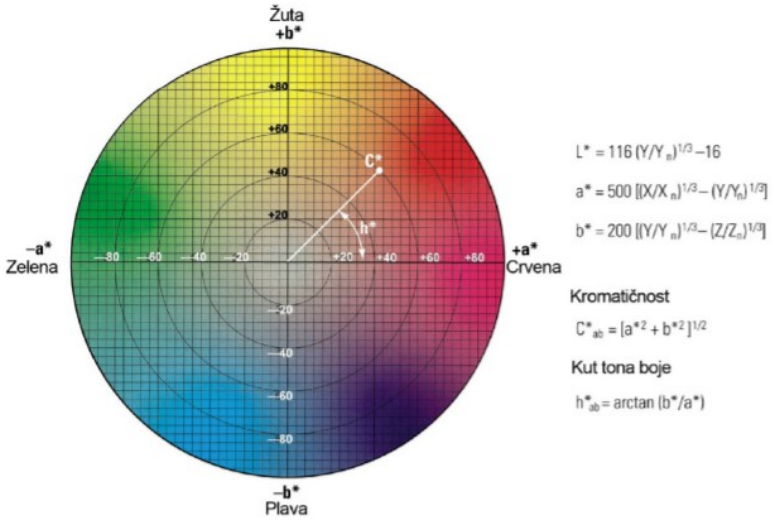


Slika 14 CIE Lab dijagram i prostor boja

Lab sustav predstavlja prostor boja ujednačenih prostornih i vizualnih razlika, a omogućuje i prikaz boja u CIE ab dijagramu kromatičnosti (Slika 15). Određen je pravokutnim koordinatama L, a i b koje su definirane odnosom:

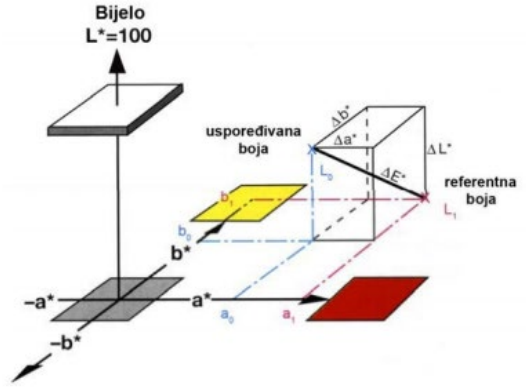
$$L = 116\,(Y/Yn^*)^{1/3}-16,\ a = 500\,[(X/Xn^*)^{1/3}-(Y/Yn^*)^{1/3}],\ b = 200\,[(Y/Yn^*)^{1/3}-(Z/Zn^*)^{1/3}]$$

* tristimulusne vrijednosti Xn, Yn i Zn odnose se na nominalni stimulus bijelog objekta uz standardnu vrstu rasvjete.



Slika 15 Dijagram kromatičnosti ab [32]

Razlika boja CIE ΔE, odnosno razliku između dvije boje u Lab modelu boja može se izraziti putem kolorimetrijske razlikom boja (ΔE*). Ona predstavlja euklidsku razliku između koordinata dvije boje, referentne L_1 i uspoređivane L_0 (Slika 16)



Slika 16 Kolorimetrijska razlika boja - CIE Lab model boja

Razlika boja (ΔE) u Lab prostoru boja se izvorno određuje po formuli (1):

$$\Delta E = \sqrt{\Delta L^2 + \Delta a^2 + \Delta b^2} \tag{1}$$

Ta formula razrađena je 1994. godine (2) te je definiran matematički izraz za određivanje razlike boja (ΔE_{94}) jer izvorno definirana razlika boja (ΔE) nije odgovarala vizualnom doživljaju razlike boja ovisno o položaju boje u CIE dijagramu kromatičnosti formula.

$$\Delta E_{94} = \sqrt{\left(\frac{\Delta L}{k_l S_l}\right)^2 + \left(\frac{\Delta C}{k_c S_c}\right)^2 + \left(\frac{\Delta H}{k_h S_h}\right)^2} \tag{2}$$

Godine 2001. prihvaćena je modificirana formula kao CIE ΔE2000 (ΔE_{00}). (3a i 3b) Razlika boja izražena kao ΔE_{00} temelji se na formuli ΔE_{94}, a cilj transformacije je poboljšanje definiranja razlike boja u plavom dijelu spektra i razlike akromatskih boja [42].

$$\Delta E_{00} = \sqrt{\left(\frac{\Delta L'}{k_L S_L}\right)^2 + \left(\frac{\Delta C'}{k_C S_C}\right)^2 + \left(\frac{\Delta H'}{k_H S_H}\right)^2 + R_T \left(\frac{\Delta C'}{k_C S_C}\right)\left(\frac{\Delta H'}{k_H S_H}\right)}$$

gdje je: $L' = L$

$a' = (1+G)a$

$b' = b$

$C' = (a'^2 + b'^2)^{1/2}$

$h' = \arctan(b'/a')$ (3a)

$$G = 0.5\left(1-\sqrt{\frac{\overline{C_{ab}}^{7}}{\overline{C_{ab}}^{7}+25^{7}}}\right)$$

gdje je $\overline{C^*_{ab}}$ aritmetička sredina vrijednosti C^*_{ab} promartanih uzoraka

$$\Delta L' = L'_b - L'_u$$

$$\Delta C' = C'_b - C'_u$$

$$\Delta H' = 2\,(C'_b C'_u)^{1/2} \sin\left(\frac{\Delta h'}{2}\right) \quad \text{gdje je } \Delta h' = h'_b - h'_u$$

$$S_L = 1+\frac{0.015(\overline{L}'-50)^2}{(20+(\overline{L}'-50)^2)^{1/2}}$$

$$S_C = 1+0.045\overline{C}'$$

$$S_H = 1+0.015\overline{C}'T$$

gdje je $T = 1-0.17\cos(\overline{h}'-30°)+0.24\cos(2\overline{h}')+0.32\cos(3\overline{h}'+6°)-0.20\cos(4\overline{h}'-63°)$

$$R_T = -\sin(2\Delta\theta)R_C$$

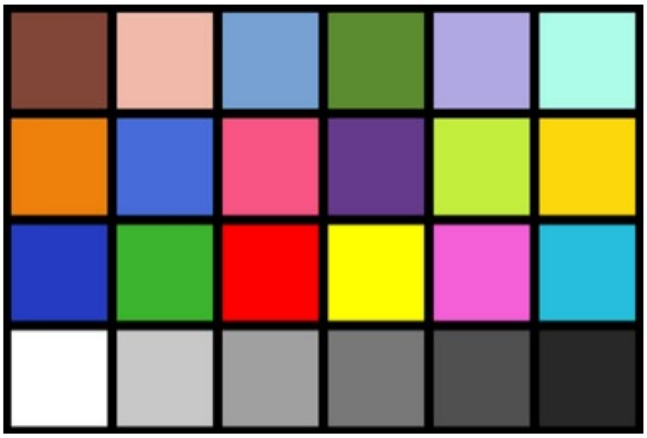
gdje je $\Delta\theta = 30\exp\{-[\overline{h}'-275°)/25]^2\}$ $\qquad R_C = 2\left(\frac{\overline{C}'^{7}}{\overline{C}'^{7}+25^{7}}\right)^{1/2}$ (3b)

Vrednovanje veličine kolorimetrijske razlike boja sa stajališta standardnog promatrača određeno je kriterijima navedenim u .Tablica 1.

Tablica 1. Vrednovanje kolorimetrijske razlike boja prema ΔE_{00}

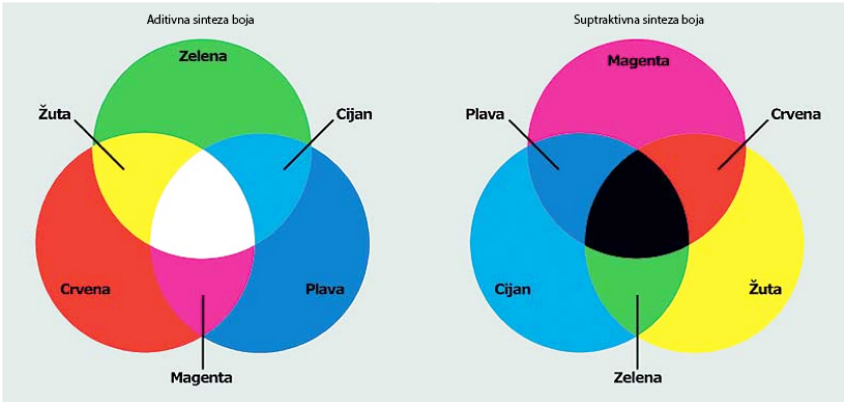
RAZLIKA ΔE*	OPIS PROMJENE
ΔE*< 1	odstupanje koje se ne zamjećuje
ΔE*= (1-2)	vrlo mala razlika; zamjetna samo iskusnom promatraču
ΔE*= (2-3,5)	srednja razlika; zamjetna čak i neiskusnom promatraču
ΔE*= (3,5-5)	velika razlika
ΔE*> 6	jako velika razlika

Za ocjenu reprodukcije boja kroz konkretni fotografski sustav promatraju se u pravilu razlike boja na standardnim tablicama boja. Tablica boja u pravilu obuhvaća primarne boje aditivne sinteze boja, primarne boje suptraktivne sinteze boja, standardne boje realnih fotografskih motiva kao što su boja kože, boja plavog neba i sl., te akromatske boje (od bijele do crne). (Slika 17).



Slika 17 Standardna tablica boja X-Rite

Kad se govori o boji, dva su osnovna načina miješanja boja: aditivna i suptraktivna sinteza (Slika 18). Obje sinteze se temelje na trikromatskom principu reprodukcije boja dok razliku stvara način kojim se miješanje ostvaruje.



Slika 18 Prikaz aditivne i suptraktivne sinteze boja [43]

U aditivnoj sintezi dodavanjem i omjerom crvenog, plavog i zelenog snopa svjetlosti različitih intenziteta, tj. njihovih valnih duljina moguće je ostvariti širok raspon različitih boja. Na mrežnici ljudskog oka postoje čunjići (Slika 3) čija se maksimalna osjetljivost djelomično preklapa s crvenim, zelenim i plavim dijelom vidljivog spektra, a boja se doživljava u ovisnosti o pobuđenosti pojedinog čunjića što znači ako se pobude samo čunjići osjetljivi na plavi dio spektra mozak promatrača takvu će pobuđenost interpretirati kao plavu boju. Npr. svjetlo koje stvara sliku gradi boje na principu ove sinteze.

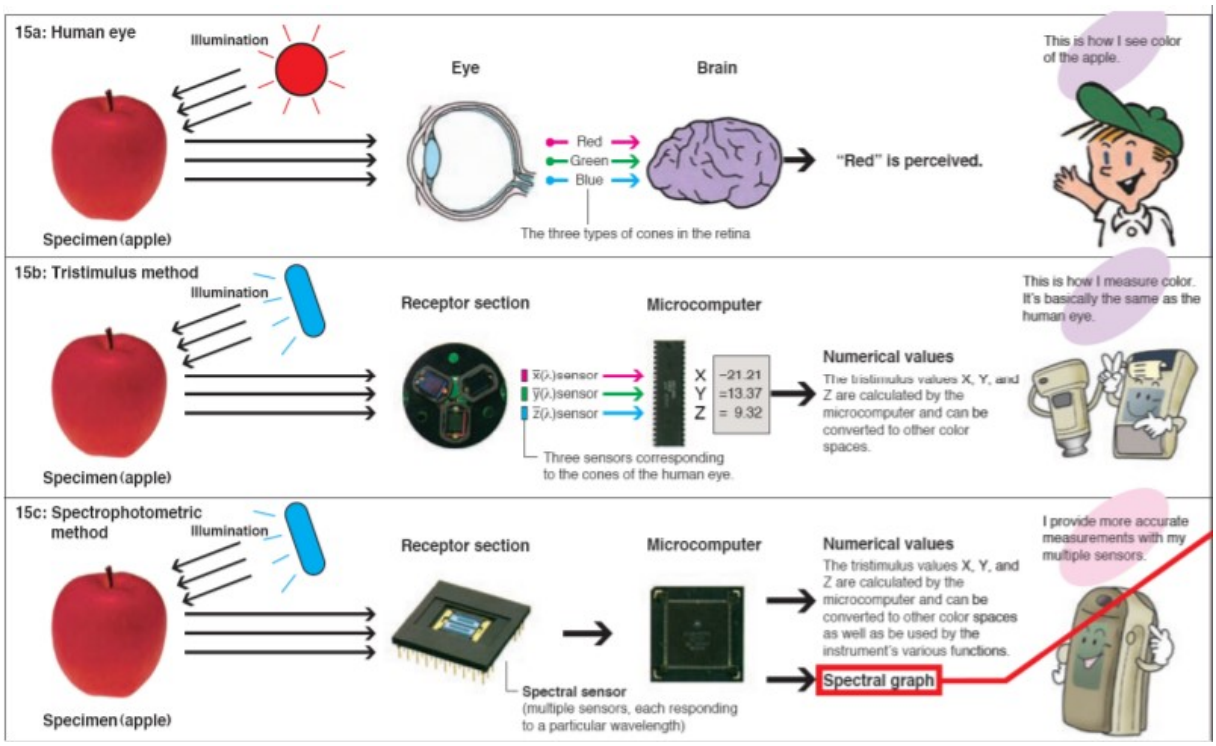
Kod suptraktivne sinteze oduzimaju se pojedine valne duljine od bijele svjetlosti, a apsorpcija se događa koristeći obojene filtere. Purpurni filter oduzima zeleni dio spektra, žuti filter

oduzima plavi dio spektra, a zeleno-plavi filter oduzima crveni dio spektra. U ovoj sintezi stupanj apsorpcije regulira raspon različitosti dobivenih boja. Kod korištenja zeleno-plavog filtera koji apsorbira crveni dio spektra od bijelog svijetla preostat će plavi i zeleni dio spektra, a u oku promatrača ostat će pobuđeni čunjići upravo na ta dva dijela spektra koja će mozak interpretirati kao crvenu boju. Klasična kolor fotografija svoje boje gradi na temelju ove sinteze. [43][44] [45] [46]

Bez obzira o kojoj se sintezi radi, dvije primarne boje sudjeluju u izgradnji sekundarne boje. Treća boja, tj. ona koja ne sudjeluje u izgradnji sekundarne boje naziva se komplementarna boja. Prema tome tri para komplementarnih boja su crvena i cijan, zelena i magenta te plava i žuta.

2.1.2. Kolorimetrija i mjerenje boja

Prema definiciji Wyszecki & Stiles, kolorimetrija je grana nauke o bojama koja se u prvom redu bavi brojčanim određivanjem boje u odnosu na određeni vizualni podražaj. S obzirom na to da je boja psihički doživljaj izazvan fizičkim podražajem, ono što se mjeri je taj podražaj odnosno svjetlo koje je ušlo u oko promatrača te u njegovom mozgu proizvelo doživljaj boje. Postoje vizualna i mjerna metoda vrednovanja boja (Slika 19).

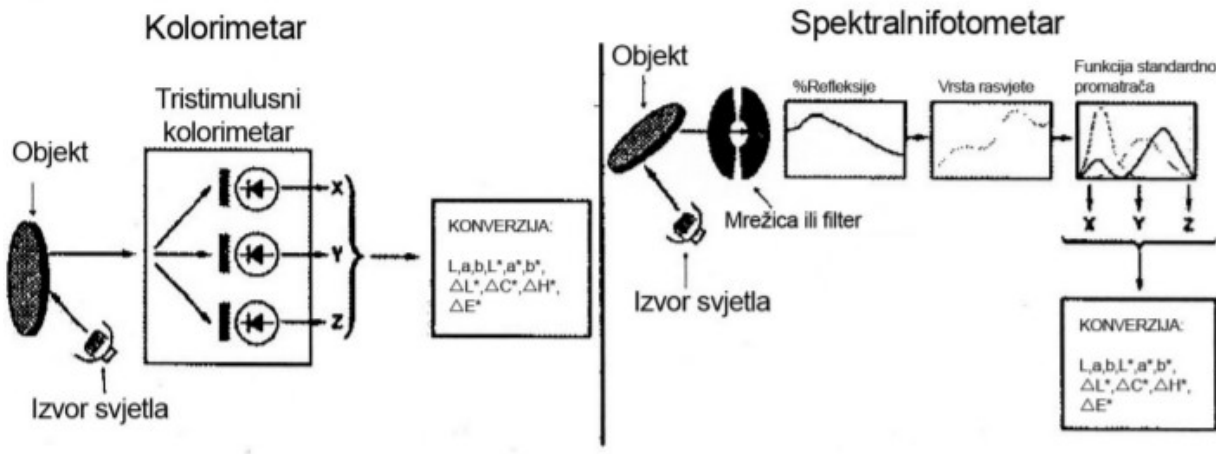


Slika 19 Usporedba doživljaja boje, tristimulusne i spektrofotometrijske metode mjerenja [33]

Vizualna metoda vrednovanja boja zahtijeva definirano osvjetljenje i standardne uvjete promatranja koji se postižu u tzv. kućici za promatranje boja (Light booth) i njihovu vizualnu ocjenu s različitim izvorima svjetla gdje se uzorci uspoređuju pod različitim izvorima svjetlosti (Tablica 3), a koristi se kod prosuđivanja jednakosti odnosno sličnosti dviju boja. [32] Postoji više vrsta različitih kućica za promatranje, a karakteristika svake je osim različitog izvora svjetla i neutralna siva pozadina.

Instrumentalno mjerenje je za razliku od vizualnog precizno definirano, a mora se provoditi tako da je u korelaciji s vizualnom procjenom. Odabir geometrije osvjetljavanja, standardnog promatrača i izvora svjetla to i omogućuje. Način mjerenja i odabir uređaja za mjerenje određuje svrha za koju se mjerenje provodi, a ona može biti određivanje doživljaja boje, određivanje pigmenta ili bojila u boji, određivanje kromatskih veličina koje definiraju razliku između dvije boje.

Od standardnih uređaja za mjerenje najčešće se koriste kolorimetar i spektrofotometar. Kolorimetar je uređaj koji se koristi kod određivanja CIE tristimulusnih vrijednosti, a spektrofotometar mjeri spektralne refleksije ili transmisije. Iako kolorimetar i spektrofotometar mjere isti raspon valnih duljina u vidljivom dijelu spektra zbog svojih karakteristika se koriste odvojeno (Slika 20).



Slika 20 Razlika mjerenja kolorimetra i spektrofotometra

2.2. Tehnike vizualnog ocjenjivanja fotografske slike

Uspoređivanje originala i reprodukcije prema određenim kvalitativnim i/ili kvantitativnim mjerilima je način vizualnog ocjenjivanja u cross media reprodukcijskom sustavu. Godine 1996. Braun, Fairchild i Alessi su definirali 5 tehnika za vizualno ocjenjivanje odnosa između originala i reprodukcije: memorijsko usuglašavanje, sukcesivno binokularno memorijsko

usuglašavanje, simultano binokularno usuglašavanje, simultano haploskopsko usuglašavanje i sukcesivno haploskopsko usuglašavanje [47]. Kao najadekvatnije za istraživanje u ovom radu odabrane su tehnike memorijskog usuglašavanja i simultanog binokularnog usuglašavanja.

Tehnika **memorijskog usuglašavanja** je tehnika kod koje se original i njegova reprodukcija ne mogu vidjeti u isto vrijeme, a promatraču nije dozvoljeno ponovno pogledati original naziva se memorijsko usuglašavanje. Na osnovi ispitanikovog pamćenja i toga kako je upamtio usporedbu u odstupanju reprodukcije od originala zasniva se ocjena ove tehnike, a ona je ujedno i najčešći način konzumacije fotografskih slika [47]. Kod tehnike **sukcesivnog binokularnog memorijskog usuglašavanja** ispitanik može u bilo kojem trenutku tražiti da ponovno pogleda original, ali se ocjenjivanje temelji isključivo na osnovi pamćenja. [47] Tehnika ocjenjivanja **simultanog binokularnog usuglašavanja** je tehnika kod koje se original i reprodukcija nalaze jedno do drugog u cijelom vidnom području istovremeno. Ocjenjivanje u ovoj tehnici provodi se simultanom usporedbom originala i reprodukcije, a ujedno daje i najpreciznije rezultate usporedbe između originala i reprodukcije. Ova metoda daje najsličnije rezultate u slučaju usporedbe s mjernim metodama (npr. prihvatljivost usporedbe boja). [47].

Simultano haploskopsko usuglašavanje je tehnika u kojoj se u isto vrijeme jednim okom promatra original dok se drugim okom promatra reprodukcija, uz postavljanje pregrade između očiju ispitanika kako bi se onemogućilo istovremeno gledanje originala i reprodukcije. [47].

Sukcesivno haploskopsko usuglašavanje je tehnika kod koje se jednim okom promatra original, a drugim okom reprodukcija, ali je ispitanik onemogućen istovremeno gledati i original i reprodukciju. [47].

2.3. Sintaksa i semantika fotografske slike

2.3.1. Sintaksa fotografske slike

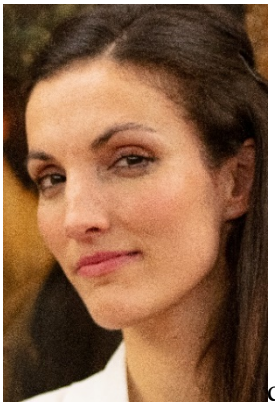
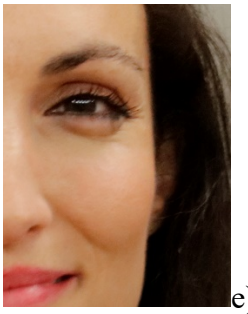
Osnovni zadatak fotografije je privući i zadržati pažnju promatrača čime se mjeri njezin uspjeh. Da bi fotografija bila uspješna određeni elementi fotografske slike se usklađuju čime se postiže cjelina, a skladna cjelina postiže se preko elemenata kompozicije fotografije. Kompozicija fotografije temelji se na formi dvodimenzionalne slike te pravila koja vrijede za dvodimenzionalnu sliku što se tiče smislene izgradnje njene forme vrijede i u fotografiji. Upravo ta pravila nazivaju se fotografskom sintaksom. Njeno poznavanje omogućuje autoru fotografu korištenje fotografijom kao alatom za postići upravo ono što želi kod svoje ciljane publike – promatrača – konzumenata fotografije, na način na koji želi i kako želi. Fotografska

sintaksa koristi indeksični, ikonički i simbolički karakter fotografije kao medija čime promatraču gotove fotografske slike prenosi ono što fotograf autor želi prenijeti.
Kompozicija fotografije obuhvaća pet elemenata: odabir motiva, smještaj motiva na samoj fotografiji, naglašavanje motiva, isticanje detalja na motivu i subjektivizaciju motiva iz pogleda autora-fotografa. Osnovni izazov kod kompozicije fotografije čini smještaj motiva na plohu i njegov odnos s okolinom što nazivamo kadriranje, a ono se može podijeliti na tri osnovna: rez kojim se određuje što se sve nalazi na fotografskoj slici, plan koji regulira odnos veličina i rakurs odnosno kut snimanja.

Plan pokriva odnos glavnog objekta na fotografiji i svega ostalog što se nalazi na njoj. Planovi mogu biti u odnosu što je bliže (predstavlja prvi plan na fotografiji), a što je dalje drugi, treći i ostale planove. Ako se radi o čovjeku kao glavnom akteru razlikujemo total (jedna ili više osoba na fotografiji), srednji plan (jedna osoba koja dominira fotografijom), bliži plan (portret osobe od struka do glave), krupni plan (samo glava) i detalj (npr. oko) (Slika 21).


a)

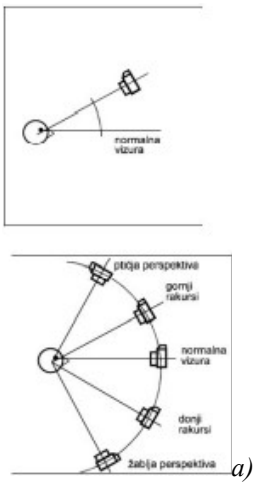
b)

c)

d)

e)

Slika 21 Planovi: a) total, b) srednji plan, c) bliži plan, d) krupni plan i e) detalj

Kut snimanja ili rakurs daje normalnu vizuru ako je motiv sniman iz visine očiju bez naginjanja fotografskog aparata. Snimanjem prema gore dobivaju se donje vizure (u krajnjem slučaju

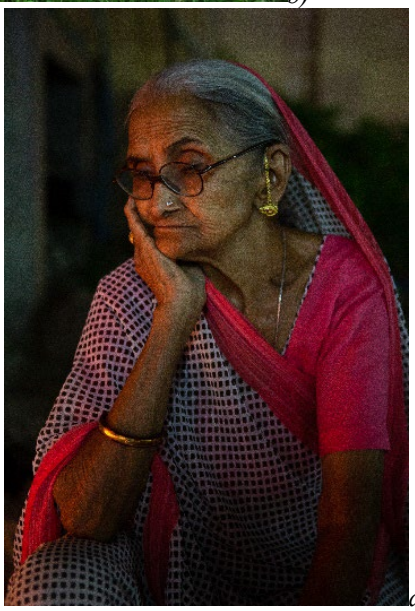
žablja perspektiva), a snimanjem prema dole dobivaju se gornje vizure (ptičja perspektiva u krajnjem slučaju) (Slika 22.)

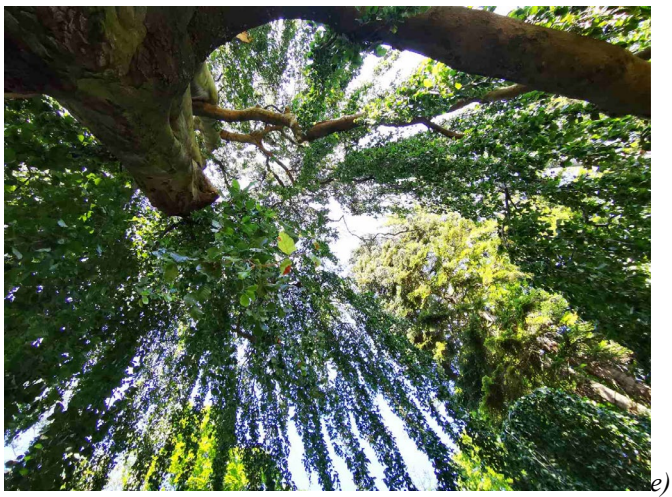


a)


b)


c)

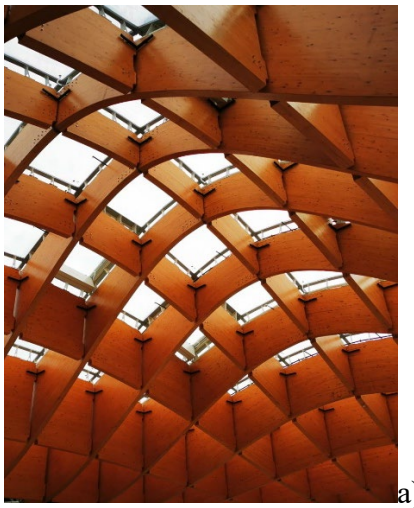
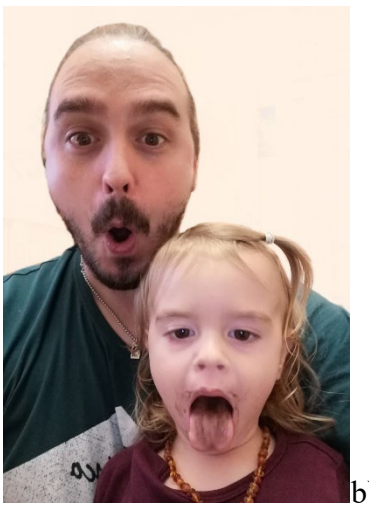
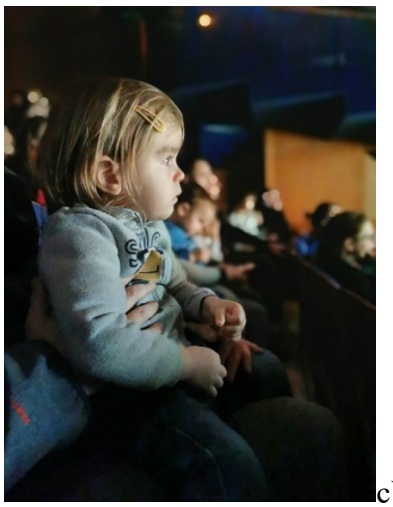

d)


e)


f)

Slika 22 Kut snimanja (rakurs): a) shema rakursa, b) normalna vizura, c) donji rakurs, d) gornji rakurs, e) žablja perspektiva f) ptičja perspektiva

Perspektivom se na fotografiji postiže dojam prostora, a vrste perspektive koje postoje su: geometrijska, vertikalna, atmosferska ili koloristička. Ako se perspektivom želi objektu na fotografiji dati značenje radi se o semantičkoj perspektivi, a koja zapravo za naglašavanje koristi neku od ranije navedene četiri perspektive. (Slika 23) Svaka od perspektiva koristi još neke perspektive, ali je samo jedna od njih dominantna na fotografiji.


a)

b)

c)

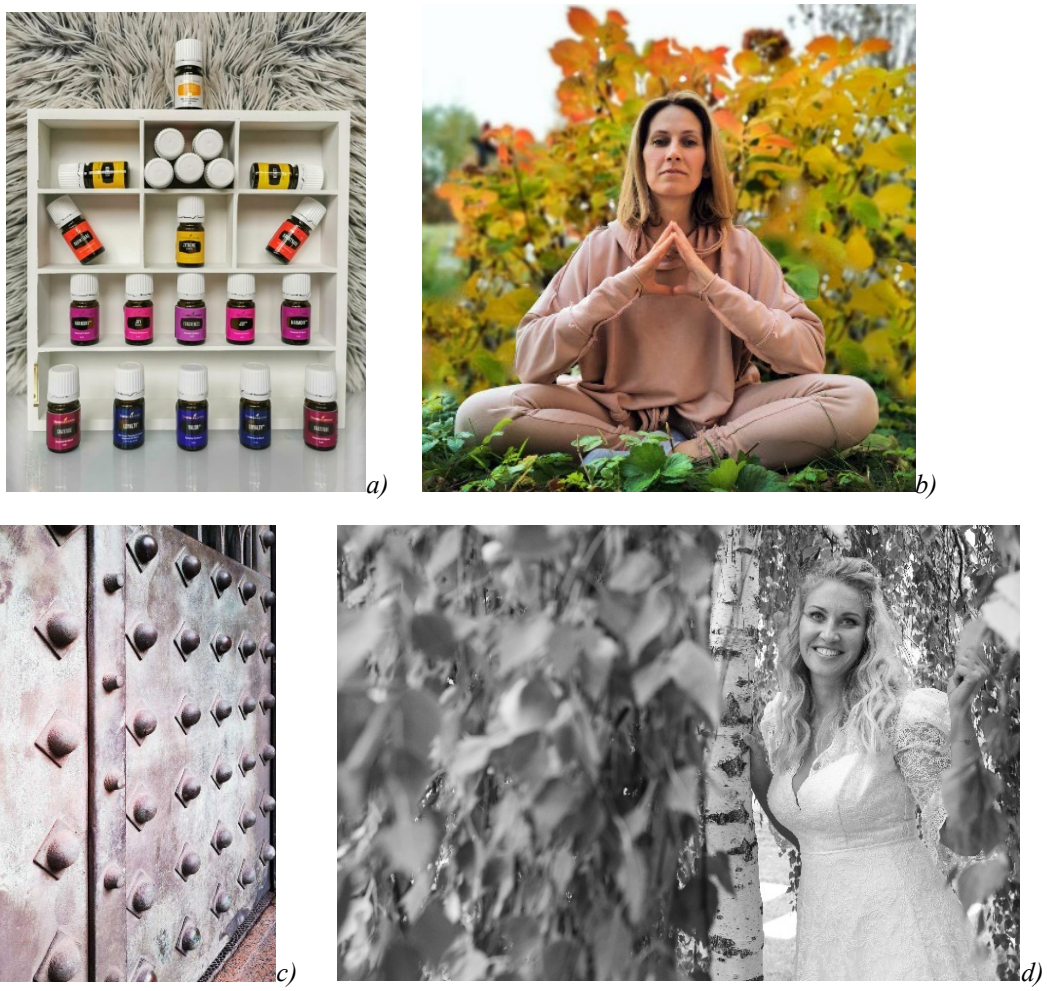
d)

e)

Slika 23 Vrste perspektiva: a) geometrijska, b) vertikalna, c) atmosferska, d) koloristička, e) semantička

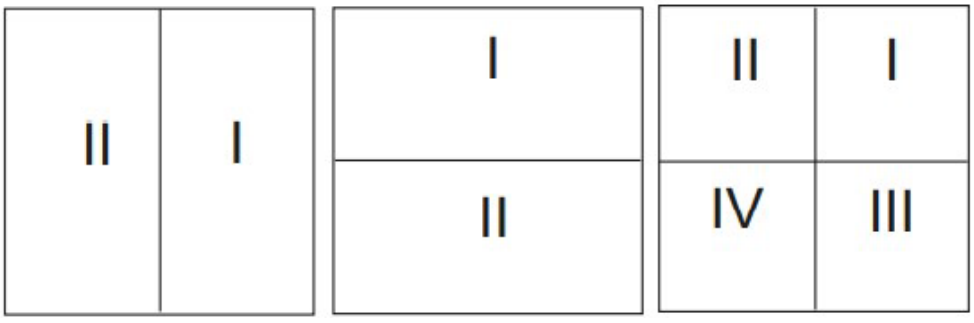
Pravilima optičke ravnoteže nazivamo simetriju, stabilnost, ritam i zlatni rez kojima na fotografiji stvaramo red. Simetrija uspostavlja optičku ravnotežu lijeve i desne strane na fotografiji, stabilnost uređuje odnos gornjeg i donjeg dijela fotografije, ritam svojim ponavljanjem osigurava dinamiku, a zlatni rez stavlja veći i manji dio slike u optičku ravnotežu

u slučaju kada se veći dio prema manjem odnosi kao cjelina prema većem dijelu fotografije. (Slika 24)



Slika 24 Pravila optičke ravnoteže: a) simetrija, b) stabilnost, c) ritam, d) zlatni rez

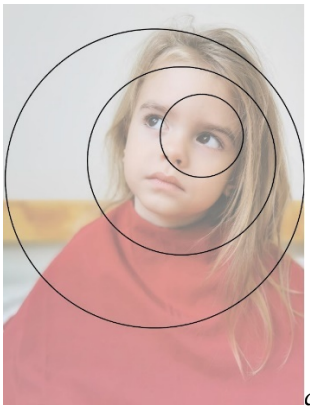
Zatim na fotografiji postoje područja interesa gdje je desni dio slike važniji od lijevog dijela, gornji je važniji od donjeg dijela, gornji desni dio je najvažniji, zatim gornji lijevi pa donji desni te zatim donji lijevi dio slike. Svaki od tih kvadranata ima svoju točku interesa gdje pogled uvijek ima svoj oslonac čak i na praznoj plohi. (Slika 25)



Slika 25 Područja interesa unutar plohe (I - najveća percepcijska vrijednost plohe i II - najmanja percepcija vrijednost plohe)
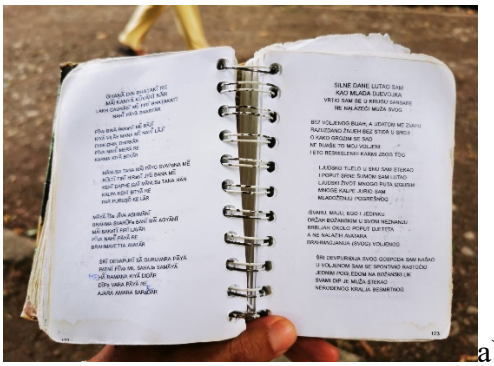
Kada pogled padne na plohu smatra se da se usmjeruje na približno 75% površine, to područje naziva se sfera interesa. Unutar te sfere pogled se zatim preusmjeruje na zonu interesa koja zaokuplja približno 30% površine slike, i konačno pogled pada na glavnu točku , tzv. točku interesa. (Slika 26)


a)

b)

c)

Slika 26 Prikaz: a) konstrukcija točke interesa; b) Sfera, zona i točka interesa, c) označene sfera zona i točka interesa

Na fotografiji postoje i linije koje se dijele na stvarne, zamišljene i psihološke linije, a zadatak im je voditi pogled prema glavnom dijelu fotografije (glavna linija i sporedne linije), a nikako ne bi smjele pogled voditi van slike jer se kaže jednom kad pogled izađe s fotografije više se nikada ne vraća. (Slika 27)


a)

b)

c)

Slika 27 Primjer korištenja linija na fotografiji: a) stvarne linije, b) zamišljene linije, c) psihološke linije

Kod linija još se mogu navesti vodoravne (daju osjećaj mirnoće), vertikalne (daju osjećaj čvrstoće i monumentalnosti), dijagonalne (daju osjećaj pokreta i dinamike) i tzv. S linije ili linije elegancije. One također mogu zatvarati i geometrijske likove (trokut-daje stabilnost ili oval-daje fokus isključivo na taj dio fotografije). Linije uređuju i smjer na slici pa tako pogled s lijeva na desno daje osjećaj odlaska, a s desna na lijevo daje osjećaj dolaska; ako vode iz donjeg lijevog u gornji desni kut fotografije predstavljaju uspon, a iz gornjeg lijevog u donji desni predstavljaju silazak.

Slika se sastoji i od tonova koji su u crno-bijeloj fotografiji njeno najjače izražajno sredstvo te ju zbog toga često i nazivaju umjetnošću svjetla i sjene. U kolor fotografiji također se koriste tonovi, ali nisu toliko dominantni kao u crno-bijeloj tehnici. Kontrast predstavlja jedno od najjačih izražajnih sredstava pomoću tonova, a definiramo ga kao razliku između najsvjetlijeg i najtamnijeg dijela fotografije. Na njega također utječu i međutonovi. Što su tonovi tamniji imaju veću optičku težinu, pa se tako tamniji tonovi često koriste na desnoj strani fotografije kako bi „zatvorili“ pogled i zadržali ga na fotografiji. Kod tonova možemo spomenuti i pojam high i low key fotografije. (Slika 28)


a)



b)

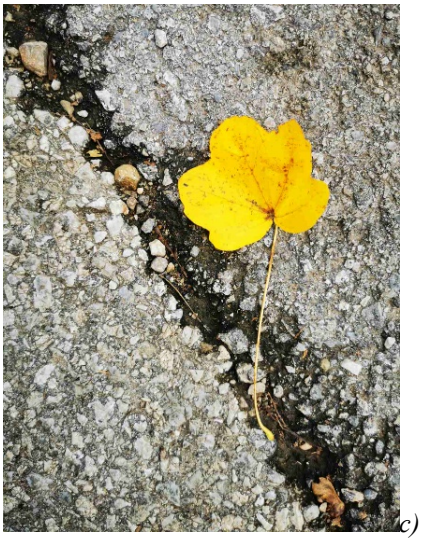

c)

Slika 28 Tonovi u kolor fotografiji: a) Kompozicija zatvorena tonovima, b) high key fotografija[48]*, c) low key fotografija*

Boja na fotografiji je glavni element izražavanja kod kolor fotografije i zapravo boja na neki način „nosi“ njenu kompoziciju. Kompozicija kolor fotografije koristi izrazite boje, prigušene boje, kontrast boja, sklad boja, prevladavajuću boju, izdvojenu boju, neprirodne boje (Slika 29).


a)


b)


c)


d)

Slika 29 Kompozicija temeljena na bojama: a)sklad boja, b) kontrast boja, c) izdvojena boja, d) prevladavajuća boja

Općenito fotografiju što se boja tiče dijelimo na dvije velike skupine – crno-bijelu i kolor fotografiju. Boju na klasičnu fotografiju možemo dodati i naknadnim dodavanjem tehnikama poput toniranja, koloriranja, zračnog kista i slično dok se u digitalnoj fotografiji boja može uređivati svim dostupnim opcijama koje nudi digitalni fotografski laboratorij – program za obradu fotografija, od kojih su danas najpoznatiji Adobe Photoshop i Lightroom. [8]

2.3.2. Semantika fotografske slike

Semantika fotografske slike potiče od semiotike, odnosno proučavanja znakova. Fotografija na neki način prikazuje znak koji označava određeni motiv/objekt. Uz velik broj različitih shema klasifikacije znakova, odnosno znakova i njihovog značenja, u fotografiji se najčešće koristi onu koja znakove dijeli na ikoničke, indeksične i simbolične (Slika 30).

Ikonički znakovi imaju jako visoki stupanj sličnosti s objektom snimanja te se fotografija općenito smatra visoko ikoničkom iako zbog prevođenja trodimenzionalne stvarnosti u dvodimenzionalnu sliku niti jedna fotografija nema u potpunosti ikonički karakter, no ako se gleda pojedinačno možemo reći da realno prikazuje objekt te da je visoko ikonička (npr. automobil). Indeksični znakovi ne pokazuju izravno objekt već posljedicu njegovog djelovanja (npr. trag automobila na nekoj površini). Simbolički znak ne uključuje direktno niti sam objekt niti posljedicu njegovog djelovanja već na neki drugi način podsjeća na objekt (npr. pejzaž gdje se odvijaju auto utrke). Najčešći vid fotografije koji koristi semantičke karakteristike fotografije je upravo reklamna fotografija koja kao načine privlačenja pažnje koristi fotografiju ugođaja (npr. zalazak sunca), fotografiju koja uvjerava (najčešće zadovoljni korisnik nekog proizvoda), fotografiju koja objašnjava (npr. fotografija dijela nekog stroja) i katalošku fotografiju (npr. realni prikaz proizvoda koji se reklamira – najviše ikonička). [8]



a)


b)


c)

Slika 30 Ikonički (a)[49]*, indeksični (b)* [48] *i simbolički karakter (c)* [49]

2.4. Fotografski motivi

2.4.1. Portret

Od izuma fotografije najizazovnije je bilo fotografirati portrete. Najveću prednost u ono vrijeme pred slikarstvom kod fotografija portreta fotografija je dobila izumom dagerotipije, kada zbog skraćenih vremena osvjetljavanja portreta pojedinci više ne moraju imati „pričvršćene“ glave posebnim uređajima, a niti prelaziti razne prepreke u samim foto studijima kako bi se zabilježila malo jača boja u obrazima što se u ono vrijeme smatralo posebno fotogeničnim. Razvojem naprednijih dagerotipija te pristupačnom cijenom fotografije postaju dostupne i širem pučanstvu čime naglo raste popularnost fotografije kao medija, te posebno portreta koji ujedno prestaju biti vezani za snimanje isključivo u fotografskom studiju.

Portretom se može smatrati fotografiju koja prikazuje karakter portretirane ličnosti onako kako ga vidi sam autor koji na fotografiju prenosi svoj stav o portretiranoj ličnosti (može se poslužiti nekom gestikulacijom, pogledom, pokretom i sl.). Najčešći problem koji se javlja je neopuštenost modela koji je svjestan da ga se fotografira. Kroz razgovor s modelom i „probno“ ispucavanje fotografija može se postići veća opuštenost modela.

Poznavanje fotografske semantike i sintakse za uhvatiti dobar portret je nužno te fotograf-autor kroz svoje fotografije mora moći zadržati pogled promatrača na slici te mu prenijeti svoja razmišljanja.

Najvažniji dio portreta u pravilu predstavlja glava portretirane osobe, te najčešće na samom portretu oči koje predstavljaju glavnu točku portretne fotografije na kojoj se u pravilu i najčešće izoštrava prilikom snimanja. Što se pogleda tiče direktan pogled u fotografski aparat predstavlja najiskreniji pogled, dok pogled u stranu može odati nepovjerenje ili lukavost.

Portret može biti pojedinačni i grupni, iako se kad se govori o portretu najčešće misli na pojedinačni portret. S obzirom na okolinu portretna fotografija se dijeli na portrete s neutralnom pozadinom i ambijentalne portrete. Prema rezu portret se dijeli na portret lica (tzv. Europski rez, rez između ramena i lakta), američki rez (rez između lakta i zgloba), portret 2/3 lika (rez iznad koljena), i portret cijelog lika.

Podjela u odnosu fotografskog aparata na položaj modela fotografiju dijeli na enface (model direktno okrenut prema fotografskom aparatu), profil, poluprofil i tročetvrtinski portret (tijelo okrenuto od fotografskog aparata, a lice prema fotografskom aparatu ili obrnuto, ali da su vidljiva oba oka).

Portreti se snimaju u različitim svjetlosnim uvjetima pa se tako razlikuju uvjeti prirodne rasvjete, rasvjete bljeskalicom, reflektorske rasvjete i raspoloživog svjetla. Modulacija prirodnog dnevnog svjetla ovisi o godišnjem dobu, ali i o dobu dana.

Za snimanje portreta najčešće se koriste portretni objektivi.

Specifično područje unutar fotografije portreta čini autoportretna fotografija kojom autor fotograf prikazuje kako vidi samoga sebe. Prvi zabilježen autoportret je onaj Roberta Corneliusa ostvaren 1839. godine u tehnici dagerotipije (Slika 31) [50]. Autoportret se do danas provlači kao čest i izazovan motiv posebno od integracije kamera u mobitele te pod popularnim nazivom „selfie“ preplavljuje društvene mreže.



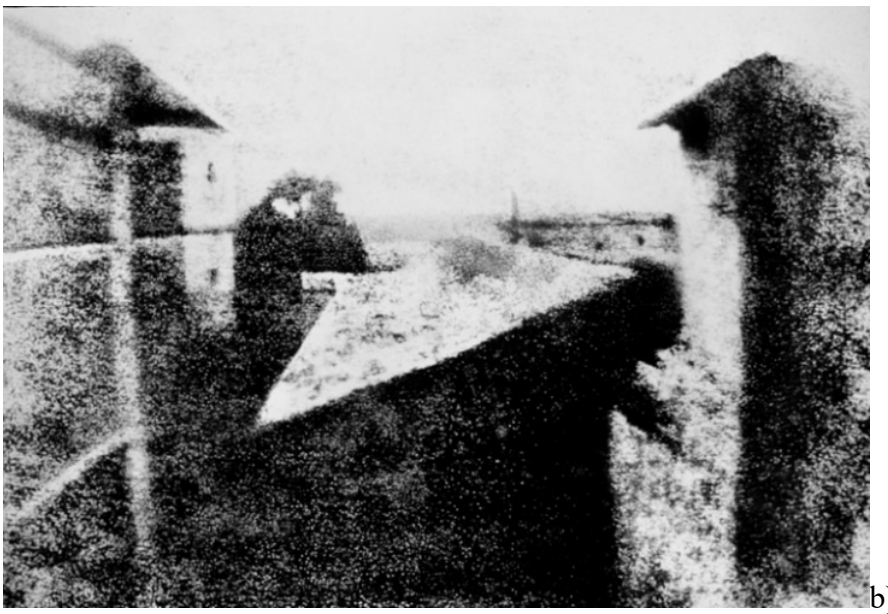
Slika 31 Robert Cornelius, Autoportret, dagerotipija, 1839. [50]

2.4.2. Pejzaž

Prva ikad zabilježena i zadržana fotografija upravo je ona pejzaža, a snimio ju je Nicéphore Niépce između 1927.g. i 1936.g. (Slika 32). Razlog zašto je baš pejzaž bio logičan izbor za zabilježiti prvu fotografiju nalazi se i u fotografskim materijalima koji su u to vrijeme bili vrlo neosjetljivi na svijetlo te su ekspozicije trajale praktički od izlaska do zalaska sunca. S obzirom

na dugu ekspoziciju na prvoj fotografiji mogu se vidjeti zgrade s lijeve i s desne strane osvijetljene suncem.


a)


b)

Slika 32 a) pločica bitumena premazana uljem korištena za ekspoziciju i b) Nicéphore Niépce, Pogled kroz prozor [51]

Prvu fotografiju pejzaža koja se smatra umjetničkom snimio je Edward Steichen 1904. godine, bila je crno-bijela, a autor je crtajući na nju dodao plave tonove i docrtao mjesec prakticirajući tehniku piktoralizma kojom su se umjetnici fotografi pokušali izdvojiti od amatera u vrijeme kad je fotografija pokušavala dobiti svoje mjesto među priznatim umjetnostima i odmaknuti od uloge koju je imala u svojim počecima gdje je prvenstveno služila slikarima kao pomoćno sredstvo za rad (Slika 33).



Slika 33 Edward Steichen, Moonlight - The Pond, 1904. [52]

Za snimanje pejzaža najčešće se koriste širokokutni objektivi.

Vrste pejzaža koje razlikujemo ovise o više faktora od kojih kad je riječ o mjestu fotografiranja govori se o planinskom pejzažu, morskom pejzažu, urbanom pejzažu (vedute), ruralnom pejzažu (prikaz sela), poljskom pejzažu, riječnom pejzažu; kad je riječ o godišnjem dobu u kojem je fotografirano razlikujemo proljetne, ljetne, jesenske i zimske pejzaže; a kad je riječ o dobu dana u kojem je fotografirano govorimo o npr. jutarnjem, podnevnom ili večernjem pejzažu.

2.4.3. **Fotografija hrane**

Fotografija hrane kao danas posebno izdvojen dio unutar promotivne fotografije izvorno spada pod fotografiju mrtve prirode, a jedne od prvih fotografija hrane bile su upravo fotografije voća i povrća na stolu, odnosno klasičnog motiva mrtve prirode (Slika 34). Povijest fotografije hrane vezana je praktički uz sam nastanak fotografije, te seže do Daguerrea i Talbota, i njihovih tehnika dagerotipije i talbotipije. Kao i kod portreta i pejzaža, ključan dio fotografije hrane, kao i svake fotografije čini svjetlo, što treba naglasiti iznova i iznova jer odličnu fotografiju osim kompozicije uvijek čini i svjetlo. U samim počecima fotografija hrane vezala se isključivo za slikarstvo što je obilježila i sama povijest nastanka fotografije kao zasebne tehnike, dok se kasnije tek fotografija počinje percipirati kao zaseban medij likovnog izražavanja te od nekih 1930.-ih godina počinje iskorištavati svoje karakteristike kao medija, te posebno naglašava svoju dinamičnost uz dizajn samih objekata snimanja. U tim godinama s dolaskom boje na fotografiju i u print izdanja dolaze na svijetlo dana i prve fotografijama ilustrirane kuharice koje

su u početku imale oblik „Bookleta“ od 3 ili 4 stranice u boji. U to vrijeme da bi se zadovoljile tehničke karakteristike medija, fotografija hrane počinje koristiti razne umjetne dodatke koji zamjenjuju prirodne sastojke hrane poput mjehurića sapunice koji su zamjenjivali pjenu piva dok je ljepilo zamjenjivalo mlijeko u žitaricama. Iako ništa od toga nije bilo jestivo, na fotografijama je izgledalo puno privlačnije od direktno snimljene hrane.



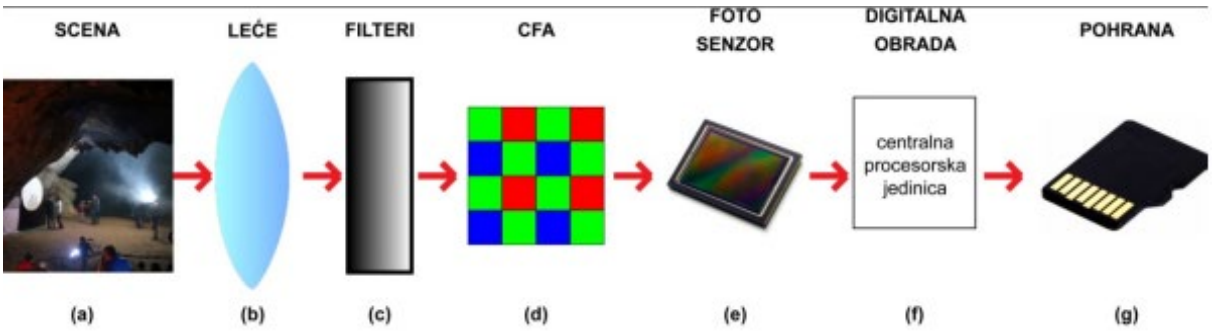
Slika 34 William Henry Fox Talbot, A Fruit Piece, 1845. Image via Wikimedia Commons [53]

Taj stil prevladava sve do 1990. godina kada se polako sve više napušta te se prednost ponovno daje dobrom svjetlu na fotografiji, atmosferi koja okružuje prikazanu hranu i umjesto teatralnog u prvi plan dolazi dokumentaristički pristup fotografiranju hrane. Pojavile su se prve kuharice gdje se fotografija svakog jela tretirala kao zasebno umjetničko djelo. Jedna od prvih tog stila je bila kuharica „White Heat“ s fotografijama Bob Carlos Clarkea. Do tad su se chef-ovi prikazivali potpuno čisti i uredni, a crno-bijele fotografije realnog prikaza stanja iz kuhinje chefa White Heata bile su tome čista suprotnost. Praktički se može reći da su kuharice od tog vremena postale poput zasebnih foto knjiga. Neki umjetnici prikazuju hranu u ljudskim ulogama (npr. stiliziraju hranu kao da su ljudi), neki umjesto hrane u prvi plan stavljaju svoj umjetnički izričaj. Bez hrane praktički nema života pa je u skladu s tim sastavni dio ljudske svakodnevice koja je kroz pojavu Instagrama i blogova hrane doživjela novi procvat postavljajući letvicu više za sve uključujući foto knjige i razne časopise. Fotografije hrane postaju sve bolje i bolje, a često uključuju i informacije o tehničkim karakteristikama dobivenih fotografija [53].

2.5. Digitalni fotografski sustav

Osnovne faze digitalnog fotografskog sustava su: snimanje, obrada i realizacija (ispis). U fazi snimanja dobiva se digitalni zapis slike snimanjem fotografskim aparatom. Digitalni zapis slike može se poistovjetiti s negativom u klasičnim negativ-pozitiv fotografskim sustavima. U ovoj fazi definiraju se osnovna kreativna i tehnička svojstva fotografije. U fazi obrade fotografije kroz daljnju obradu digitalnog zapisa slike bitno se utječe na konačne karakteristike fotografije. Obrada fotografija sastoji se od cijelog niza različitih radnji koje definiraju kreativne (sintaktičke i semantičke) i tehničke karakteristike finalne fotografije. U digitalnom fotografskom sustavu to znači rad u odgovarajućem programu za digitalnu obradu slike koji se može nazvati "digitalni fotografski laboratorij" jer se u njemu odvija ono što se odvijalo u fotografskom laboratoriju za izradu klasičnih fotografija negativ-pozitiv fotografskog sustava. [54][8]

U fazi snimanja nastaje digitalni fotografski zapis slike. Kako bi on nastao u digitalnom fotografskom aparatu izvršava se niz radnji koje će rezultirati digitalnim zapisom fotografske slike. Procesi koji se pri tome odvijaju opisani su u shematskom prikazu koji slijedi (Slika 35).



Slika 35 Shema procesa nastajanja digitalnog fotografskog zapisa fotografije [55]

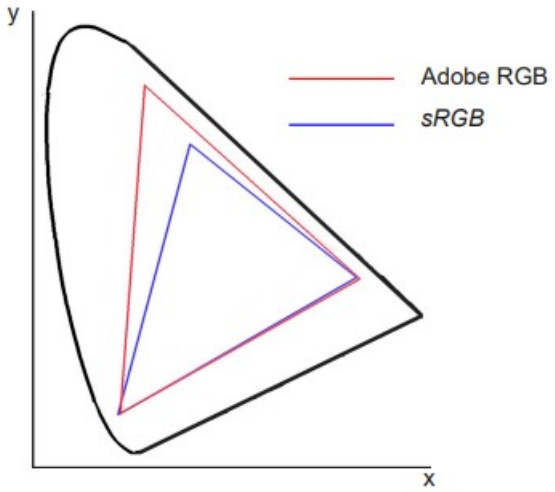
Pri nastanku digitalnog zapisa fotografske slike svjetlo sa scene (a) fokusira prema fotoosjetljivom mediju pomoću optičkih leća odnosno objektiva (b). Objektivi kontroliraju veličinu scene koja se snima te pomoću zaslona na objektivu količinu svjetla koja dolazi do fotoosjetljivog senzora. Svjetlo zatim prolazi kroz niz filtera – antialising, infracrveni i tzv. CFA (color filter array) koji je izveden kad mozaik filtera boja, a svi ti filteri pomažu da se formira digitalni zapis slike. CFA filter se postavlja ispred fotoosjetljivog medija, odnosno senzora, a služi nam za dobivanje informacija koje stvaraju fotografiju u boji. Najbitnija komponenta

digitalnog fotografskog aparata je senzor. Dva najpoznatija tipa senzora su CCD i CMOS senzori koji se tehnološki bitno razlikuju. Sastoje se od piksela – fotoosjetljivih ćelija koje bilježe intenzitet svjetla i time daju monokromatsku sliku koja prolaskom kroz CFA filter koji razdvaja različite valne duljine svjetla postaje slikom u boji (d). Nakon prolaska svjetla kroz CFA senzor svjetlo dolazi na fotoosjetljivi senzor (e). Ako senzor zamislimo kao dvodimenzionalnu matricu piksela s jednom x i y osi, rezoluciju fotografije definiramo kao broj piksela po osi x pomnožen s brojem piksela po osi y. Vrijednost koju dobijemo množenjem je skup pozitivnih brojeva koji prikazuju vrijednost intenziteta svjetla ovisnu o tome koliko bitova je sadržano u sustavu. Intenzitet svjetla od 256 nivoa zapis (RGB, 0 do 255) ima 8-bitni sustav gdje vrijednost nula predstavlja crnu ili potpuni nedostatak svjetla, a vrijednost 255 prikazuje bijelu boju ili potpunu (maksimalnu) prisutnost svjetla. RGB vrijednosti u programu za obradu slika također idu od vrijednosti 0 do 255. Senzor provodi proces kvantizacije, što znači prenošenje intenziteta svjetla u konačnu sliku pretvaranjem intenziteta svjetla u najbliži cijeli broj čime dolazi do malih gubitaka u samoj slici. Nakon što je uz pomoć senzora za svaku boju zabilježen intenzitet svjetla dodatnom obradom dobivenih informacija dobiva se vrijednost boja za svaku od primarnih boja. Taj proces se naziva interpolacija, a zadatak mu je pretvoriti monokromatsku matricu u kolor fotografiju. Pretvorbom u kolor sustav interpolacijom dobivaju se tri kolor sloja – crveni, zeleni i plavi. Svaki proizvođač fotografskih aparata ima svoj, različiti proces interpolacije, koji se također razlikuje i od modela do modela fotografskog aparata. [56][57]

U procesu daljnje obrade kroz interni procesor odvijaju se i gama korekcija i bijeli balans (f). Medij za pohranu podataka po završetku obrade svih informacija pohranjuje izrađenu fotografiju (g). Tako nastala fotografija može sadržavati sirovi zapis (.raw, .cr2, itd.), zapis bez gubitka pri kompresiji (.tiff), bitmape (.bmp) ili zapis s gubitkom poput JPEG formata. Nakon pohranjivanja na medij za pohranu fotografija se dalje može prenositi i duplicirati bez ikakvih gubitaka kvalitete fotografije ili njenih informacija. [58] [59]

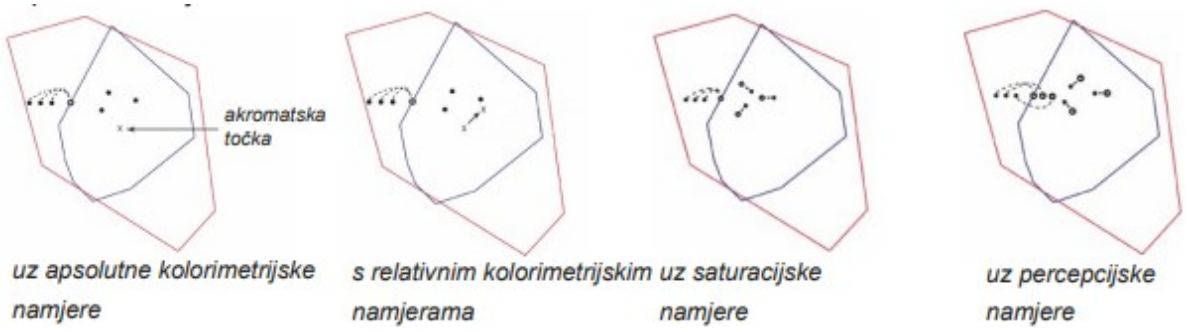
Faza snimanja završava tako da je fotografska slika zabilježena u digitalnom zapisu u nekom od prije navedenih formata određene rezolucije, potencijalno nivoa kompresije (u slučaju zapisa s kompresijom), dubine boje (u slučaju sirovog zapisa) i prostora boja. U pravilu, u većini slučajeva fotografska slika je zabilježena u Adobe RGB prostoru boja; u zapisu s kompresijom kao 8 bitni zapis po kanalu, a u sirovom zapisu kao više nego 8 bitni zapis, a ovisno o karakteristikama senzora fotografskog aparata. Bez obzira na koji način je definiran 8 bitni format zapisa koji je u početku zapisan u Adobe RGB prostoru boja iz tog prostora boja se

redefinira u reproducibilni sRGB prostor boja u kojem boje vidi većina izlaznih uređaja kao npr. monitori, printeri, projektori i dr. (Slika 36).



Slika 36 Adobe RGB i sRGB prostor boja u CIE 1931 dijagramu kromatičnosti [60]

Prebacivanje zapisa slike iz jednog prostora boja u drugi prostor boja naziva se renderiranje. Postoje četiri vrste renderiranja: renderiranje uz apsolutne kolorimetrijske namjere, renderiranje s relativnim kolorimetrijskim namjerama, renderiranje uz saturacijske namjere te renderiranje uz percepcijske namjere koje se još naziva i fotografsko renderiranje. (Slika 37).



Slika 37 Vrste renderiranja

Renderiranje uz percepcijske namjere boje iz jednog prostora boja prebacuje u drugi tako da se doživljajno (percepcijski) ukupni dojam slike što manje mijenja. Dolazi do određenih kolorimetrijskih promjena boja pri čemu se manje zasićene boje mijenjaju manje, a zasićene boje više - "komprimiranjem" u manji prostor boja, ali tako da se i dalje sve boja šireg prostora razlikuju i u užem prostoru boja. Ovo renderiranje je reverzibilno.

Renderiranje uz apsolutne kolorimetrijske namjere prebacuje boje iz šireg prostora boja u uži uz zadržavanje njihove apsolutne kolorimetrijske vrijednosti. Boje iz šireg prostora boja čije je

zasićenje veće od zasićenja užeg prostora boja u koji se prebacuju, prevode se u odgovarajuće maksimalno zasićene boje užeg prostora boja.

Kod renderiranja s relativnim kolorimetrijskim namjerama vrijedi isti princip kao kod renderiranja s apsolutnim kolorimetrijskim namjerama, ali se ovdje uzima u obzir pomak bijele u užem prostoru boja u koji se prebacuje iz šireg prostora boja.

S obzirom na to da se kod oba postupka renderiranja s apsolutnim ili relativnim kolorimetrijskim namjerama u užem prostoru boja u koji se boje prebacuju u potpunosti gube razlike boja koje su izvan užeg prostora boja te se javljaju i problemi kod finog prelaza tonova, ova se renderiranja ne koriste kod prebacivanja fotografija iz šireg u uži prostor boja. Iznimno ovakvo se prebacivanje može koristiti u slučajevima kada fotografija ne sadrži bitne informacije u zasićenim bojama.

Renderiranje uz saturacijske namjere maksimalno zasićene boje iz jednog prostora boja prevodi u maksimalno zasićene boje drugog prostora boja uz zanemarivanje razlika između tona, svjetline i zasićenja pojedine boje. Iz tog razloga nije primjereno za prebacivanje boja u području digitalne fotografije.

Sustav obrade digitalne fotografije podrazumijeva kvalitetnu obradu digitalnog zapisa fotografije do finalne fotografije, a da bi to bilo moguće moraju biti ispunjeni osnovni hardverski i softverski zahtjevi. Takav sustav može se nazvati i digitalnim fotografskim laboratorijem s obzirom na to da se u klasičnoj fotografiji za proces izrade i obrade fotografija koristi naziv tzv. crna komora ili klasični fotografski laboratorij, a oboje kao rezultat daju gotovu/finalnu fotografiju. Minimalni hardverski zahtjevi, bez obzira o kojoj se vrsti računala radi ovise o korištenim softverskim rješenjima kao i karakteristikama digitalnih zapisa fotografije, posebice što se tiče memorije koja je potrebna za nesmetan rad kod učitavanja i same obrade. Procjena tonova, boja i ostalih tehničkih karakteristika fotografije u toku obrade prvenstveno ovisi o procjeni autora-fotografa koja se donosi na osnovi vizualne ocjene slike na monitoru računala zbog čega je izuzetno bitan odgovarajući monitor. Glavne dvije skupine monitora čine LCD i CRT monitori, a uz njih tu su i OLED monitori [61][62][63]. Današnji se monitori računala baziraju najčešće na LCD tehnologiji. Kod monitora s katodnom cijevi, elektronski top (katoda) se grije čime se stvara snop elektrona koji su fokusirani na premazani zaslon. Udarom elektrona na fosfor se stvara svjetlo, a da bi se dobila višebojna (kolor) slika, fosfor je obojen plavo, zeleno, odnosno crveno. Višebojna, kolor, slika nastaje aditivnom sintezom. Kako bi zasvijetlila fosforna točkica željene boje, između zaslona i izvora elektrona nalazi se metalna raster ploča. LCD monitori se temelje na tehnologiji tekućih kristala tj. tekućim ili polutekućim tvarima čije se molekule, pod utjecajem električnog polja, ponašaju

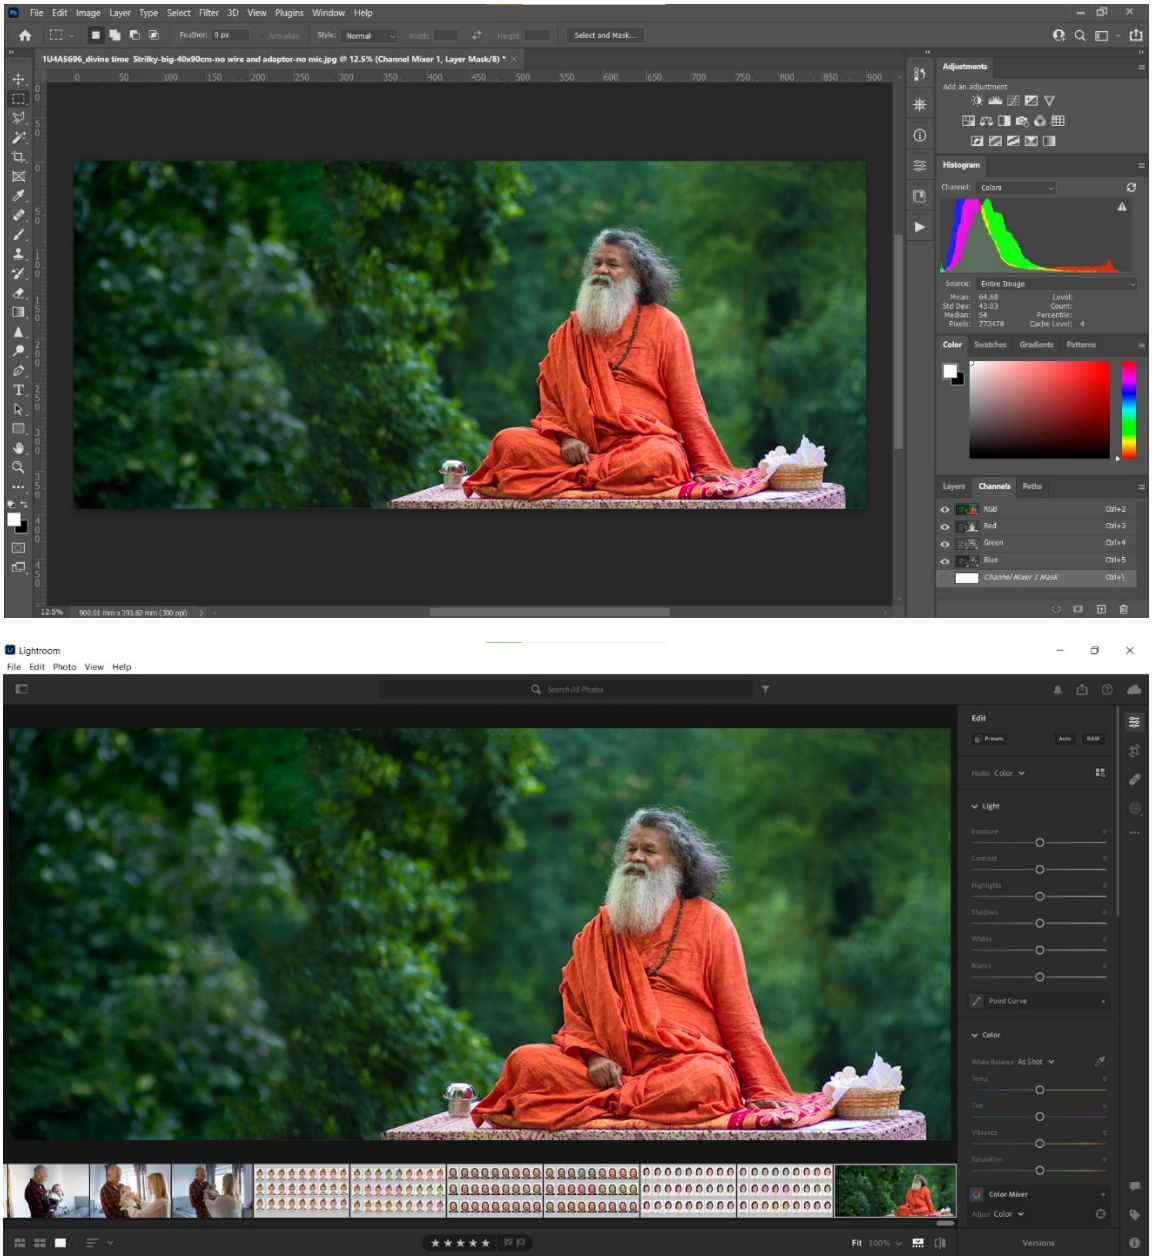
kao kristali koji mogu polarizirati svjetlo te ga propuštati ili ne. LCD monitori se sastoje od slojeva tekućih kristala koji se nalaze na pločama plavog, zelenog i crvenog filtera te se, kao i kod katodnih cijevi, višebojna slika gradi aditivnom sintezom. LCD monitori su lakši i tanji te pri radu manje zamaraju oči, ali stvaraju i više problema s procjenom boje. Za kvalitetan rad u digitalnom fotografskom laboratoriju dijagonala monitora mora biti minimalno 38 cm, a rezolucija 1024 x 768 piksela. Za korektnu je reprodukciju boja, uz to, potrebna i kalibracija monitora kroz tri faktora – kromatski, bjelinu i gammu. Kromatski faktor definira ton i zasićenje, bjelina čistoću bijele, a gamma odnos svjetline i kontrasta. Monitori za Machintosh pretežno su kalibrirani na gamma 1.8, a PC 2.2 (što približno odgovara TV ekranima) (Slika 38).



Slika 38 Utjecaj odabira monitora na obradu fotografije: a) fotografija portreta i standardne tablice boja obrađena uz gamma 2,2 (PC) i b) fotografija portreta i standardne tablice boja obrađena uz gamma 1,8 (Apple Macintosh) [60]

Ovaj se problem može vezati i uz prevladavanje pojedinih operativnih sustava u pojedinim područjima, npr. SAD – Machintosh, Europa – PC. Kalibracija monitora se može provesti instrumentalno – pomoću uređaja koji se učvrsti na monitor (uređaji su različiti – ovisno da li se radi o LCD monitoru ili onom s katodnom cijevi) ili softverski - najpoznatiji softverski "alat" za kalibraciju monitora je Adobe Gamma koji može učitati 153 već postojeća ICC profila ili voditi korisnika kroz nekoliko standardnih koraka kojima se ugađa svjetlina, kontrast, gamma i čistoća bijele. OLED je poboljšanje na LCD zaslonu koje pruža bolju boju i kut gledanja, ali također zahtijeva veću snagu.

Softverska rješenja za obradu digitalnih zapisa fotografije mogu biti iz skupine besplatnih ili plaćenih programa, a od plaćenih najpoznatiji su programi iz Adobe paketa koji se nametnuo kao profesionalni standard. Za obradu fotografija prvenstveno tu su Photoshop i Lightroom te Camera Raw (isključivo za predobradu sirovih zapisa). (Slika 39, Slika 40)



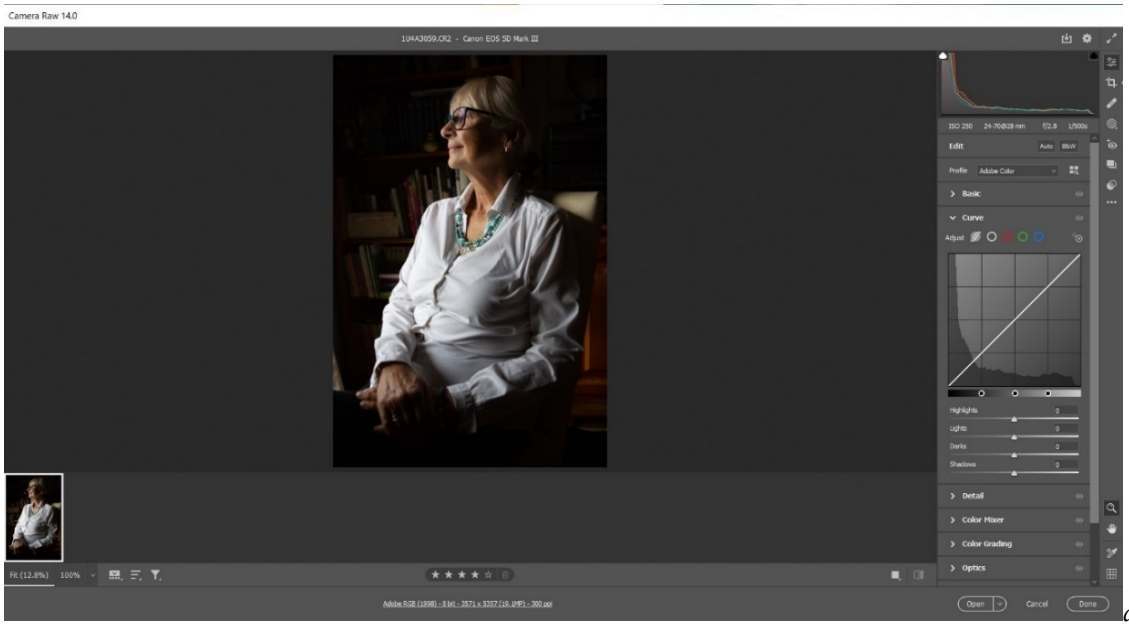
a)

b)

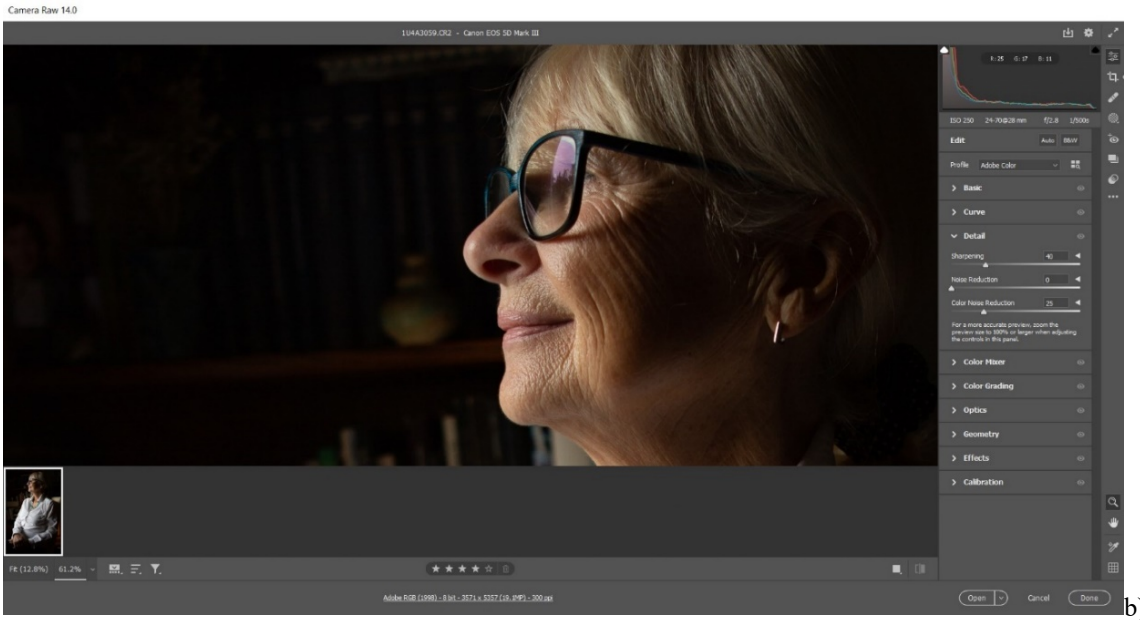
Slika 39 Digitalni zapis fotografije učitan u Adobe Photoshop(a) i Adobe Lightroom (b)

Sirovi format fotografija otvara se najprije u Camera Raw programu (Slika 40) gdje se mogu podesiti postavke koje podešava autor-fotograf na kameri kod fotografiranja. Te se postavke ovdje mogu pregledati i ponovno podesiti do željenih prema izboru autora-fotografa i zatim se iz njega prebaciti u Adobe Photoshop na daljnju obradu. Adobe Photoshop koristi različite alate za obradu (npr. za selekciju, maskiranje, za rezanje, za crtanje, bojanje, mjerenje, ravnanje, brisanje, posvjetljivanje ili potamnjivanje i drugo) kojima se utječe direktno na zapis slike dok se u Camera Raw ili Adobe Lightroom programu promjena zapisuje u zasebni file ostavljajući originalan zapis slike netaknut čime se on uvijek može promijeniti i naknadno, nakon što je slika u nekom trenutku u vremenu bila obrađena i spremljena što u Adobe Photoshop programu

nije moguće. Neke od postavki koje se mogu napraviti u Camera Raw programu su redefiniranje bijelog balansa, postavki ekspozicije, zasićenja boja, podešavanja tonova, korekcije boja, uklanjanja šuma, izoštravanja, i dr.



a)

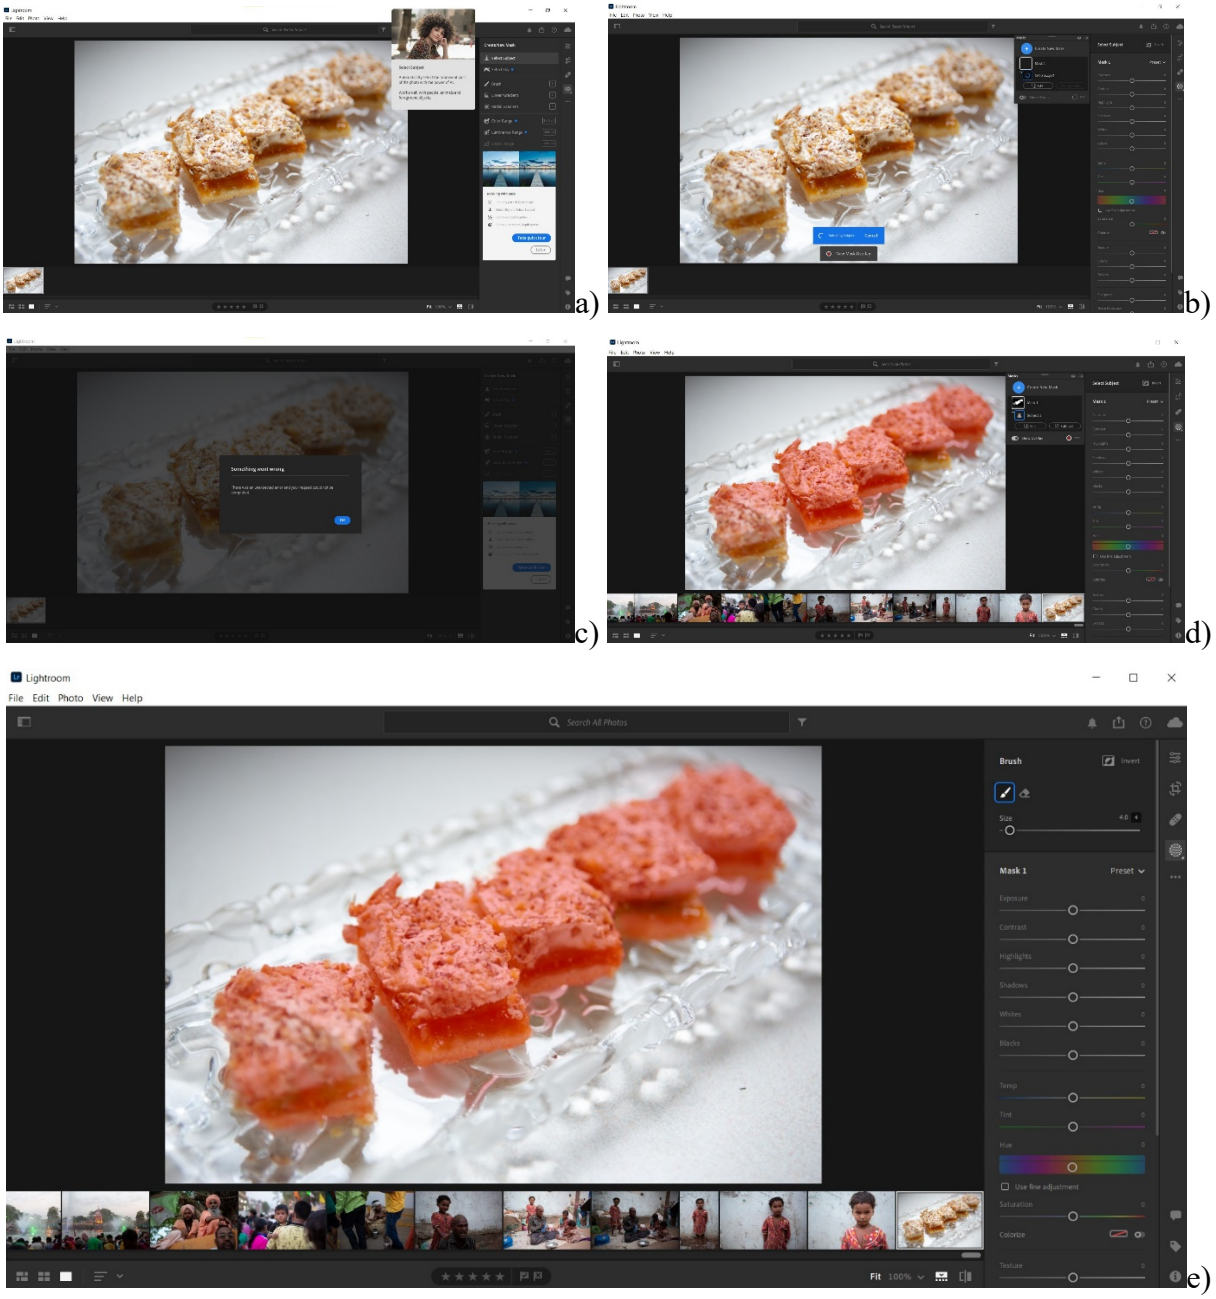


b)

Slika 40 Predobrada fotografije u Camera Raw programu: a) podešavanje tonova (tonska krivulja), b)izoštravanje, uklanjanje šuma

Jedna od najvećih prednosti obrade u Adobe Lightroom programu je npr. korištenje sustava za maskiranje koje je u najnovijim programima napravljeno izuzetno napredno te pri odabiru maske odmah nudi odabir automatskog maskiranja subjekta na fotografiji ili neba (Slika 41). Uz dovoljno jake hardverske postavke nešto što se prije obrađivalo i do petnaestak minuta bude

odrađeno najčešće u manje od minute što profesionalnom fotografu autoru znači značajnu uštedu na vremenu i povećava brzinu rada.



Slika 41 Adobe Lightroom, postupak izrade maske: a)odabir automatskog odabira maske objekta, b) procesuiranje maske, c) u slučaju slabijih karakteristika hardverskog sustava javlja se greška, d) odrađena automatska selekcija subjekta, e) nadopunjena selekcija korištenjem brush opcije

Idealni uvjeti za obradu fotografija gledanjem slike na monitoru računala su osvjetljenje prostora od 64 lx uz D50 temperaturu izvora svjetla. Maksimalna refleksija svjetla od površine monitora iznosi do 20% iluminacije prostora, a njegova pozadina do 29% iluminacije monitora. Zbog teškog postizanja i održavanja ovih uvjeta zadovoljavajućim karakteristikama smatra se i

prostor bez prirodnog izvora svjetla, ali uz izvor svjetla što stalnijih karakteristika, te tamnijih neutralnih zidova bez svijetlih predmeta u prostoriji.

Uz razne opcije koje nude tehničke postavke sustava i sustavi obrade različitih programa za obradu digitalnih zapisa slike, fotografija je ipak primarno kreativno djelo autora-fotografa, a njene tehničke karakteristike ovise o autorovoj subjektivnoj procjeni temeljenoj na iskustvu.

2.6. Histogram digitalnog zapisa fotografske slike

Histogram digitalnog zapisa fotografske slike predstavlja grafički prikaz distribucije tonova, tj. raspoređenost piksela po pojedinom tonu. U slučaju 8 bitnog RGB zapisa to znači da je u svakom kanalu moguće razlikovati 256 tonova (od 0, što predstavlja crnu, do 255, što predstavlja bijelu). Ukupno se tako razlučuje 2563, odnosno 16777216 tonova (boja). Pri tome lijeva strana histograma prikazuje tamna, a desna svijetla područja. Ako je prilikom snimanja fotografija preeksponirana, većina je piksela na histogramu, u odnosu na histogram korektno eksponirane fotografije, prikazana u desnom, a ako je fotografija podeksponirana u lijevom dijelu. Kod zapisa fotografije scene uravnoteženih tonova i boja, uz ravnomjerno osvjetljenje, histogram je uravnotežen kroz cijelo područje s manje naglašenim, nečešljastim, brjegovima i dolovima. (Slika 42)

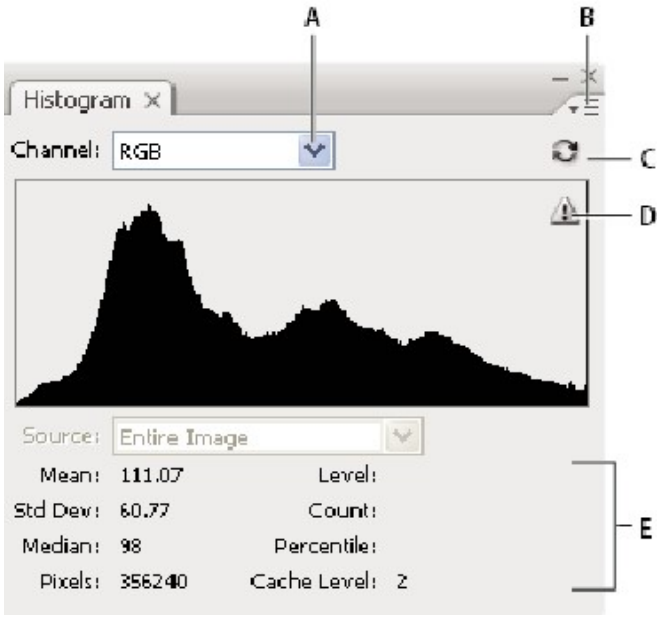

a)


b)


c)

Slika 42 Histogram digitalnog zapisa fotografije: a) normalno eksponirana fotografija b) simulacija preeksponirane fotografije c) simulacija podeksponirane fotografije

Na donjoj slici na prikazu histograma slovom A označen je izbornik za promjenu kanala slike, slovom B izbornik panela, slovom C broj piksela izračunat kroz predmemoriju za brži prikaz, slovom D označeno je upozorenje da se ne prikazuje stvarno stanje histograma nego predmemorijski prikaz i slovom E označena je statistika histograma. (Slika 43)



Slika 43 Dijelovi histograma [64]

Statistički dio histograma prikazuje informacije za *Mean*, *Std Dev*, *Median*, *Pixels*, *Level*, *Count*, i *Cache Level*. *Mean* predstavlja prosječnu vrijednost intenziteta. *Std Dev* predstavlja standardnu devijaciju koja prikazuje koliko široko variraju vrijednosti intenziteta. *Median* pokazuje srednju vrijednost u nekom rasponu vrijednosti intenziteta. *Pixels* predstavljaju ukupni broj piksela korištenih za izračun histograma. *Level* prikazuje vrijednost intenziteta područja ispod pokazivača. *Count* prikazuje ukupni broj piksela koji odgovaraju intenzitetu vrijednosti ispod pokazivača. *Percentile* prikazuje kumulativni broj piksela na ili ispod razine ispod pokazivača, a ova je vrijednost izražena kao postotak svih piksela na slici od 0% skroz lijevo do 100% skroz desno. *Cache Level* prikazuje trenutnu predmemoriju slike korištenu da se izradi histogram. U slučaju kada je *Cache level* veći od 1, histogram se brže prikazuje i u tom slučaju napravljen je iz reprezentativnog uzorkovanja piksela slike temeljene na povećanju. Originalna slika ima predmemoriju slike 1. Na svakom nivou iznad nivoa 1, četiri susjedna piksela se uprosječuju kako bi se dobila vrijednost jednog piksela. To znači da je svaki nivo upola manjih dimenzija odnosno ima ¼ broja piksela nižeg nivoa. Kada Photoshop radi brzu

procjenu može se koristiti jednim od gornjih nivoa. Gumb *Uncached Refresh* omogućuje ponovno crtanje histograma korištenjem stvarnog sloja slike. [64]

Histogram pokazuje detalje u sjenama prikazane na lijevom dijelu histograma, srednje tonove prikazane u sredini i svijetle tonove prikazane u desnom dijelu histograma. Pomoću histograma može se odrediti da li fotografija ima dovoljno detalja kako bi se mogla napraviti dobra korekcija. Praktično daje brzi pregled tonske vrijednosti slike. Korektno osvijetljena slika sa širokim rasponom boja, ima neke piksele raspoređene u svim dijelovima histograma (Slika 43). Histogram digitalnog zapisa fotografske slike može se smatrati jednim od osnovnih alata pri objektivnoj analizi tonova i boja, a analiza se provodi na histogramu cjelokupnog zapisa ili pojedinih kanala. [64]

3. EKSPERIMENTALNI DIO

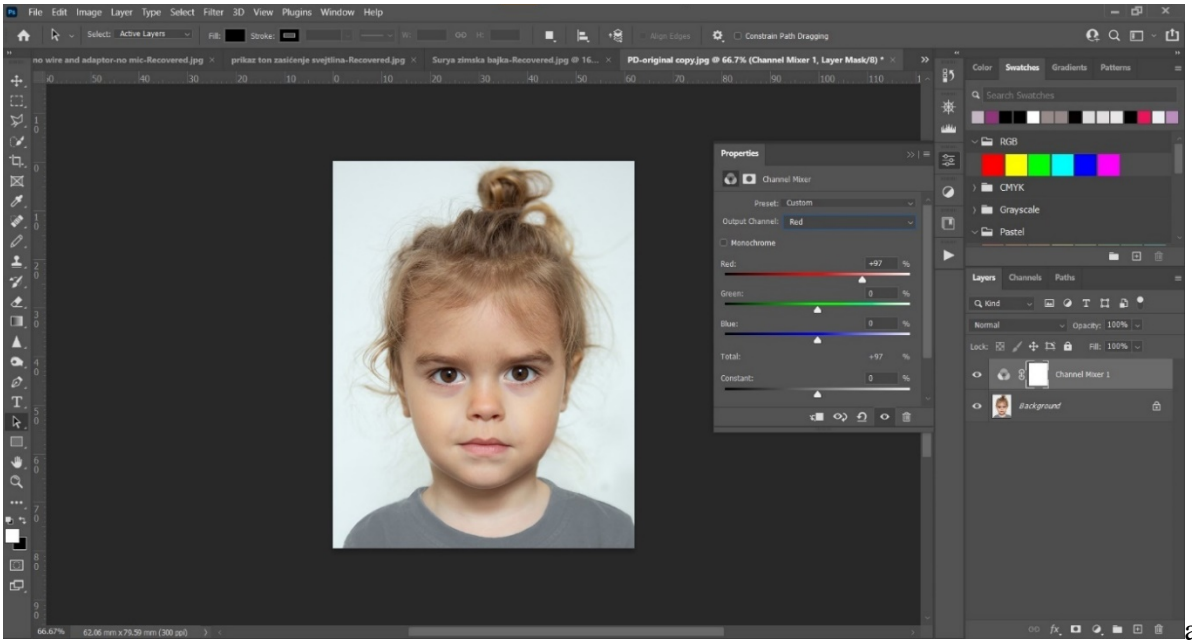
3.1. Metodologija i plan istraživanja

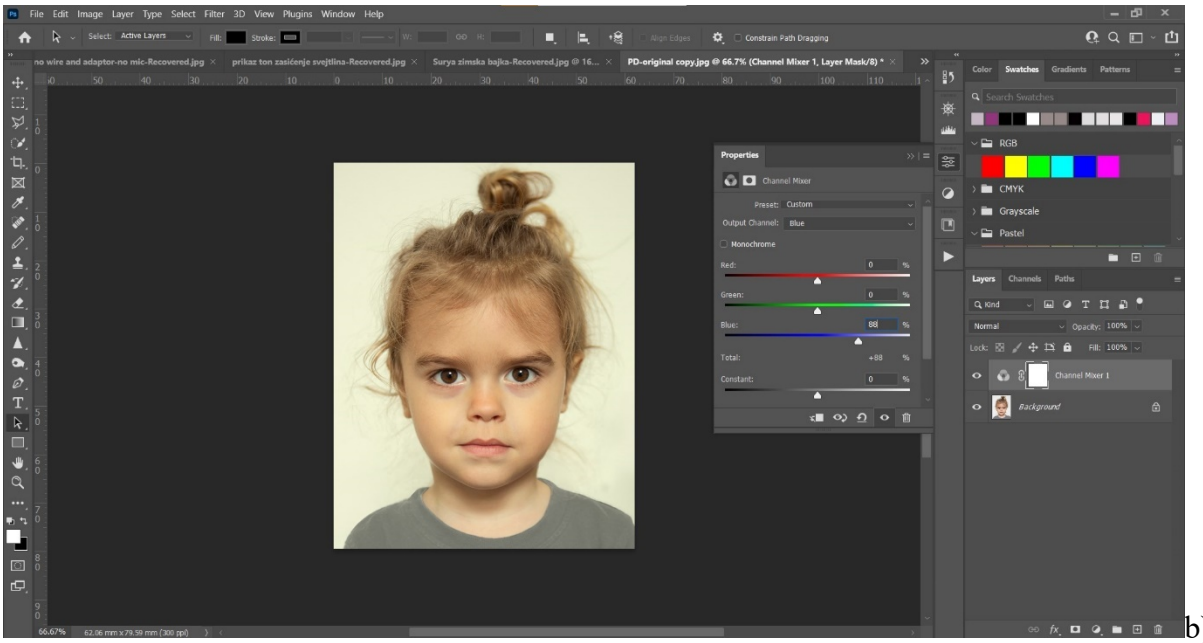
Istraživanje se temelji na vizualnim procjenama ispitanika i primjeni mjernih metoda. Za potrebe istraživanja snimaju se testne fotografije odabranih motiva i sintaktičkih postavki (Slika 44).



Slika 44 Testni motivi snimljeni za istraživanje: a) motivi portreta (ženski, muški i dječji portret) snimljeni za istraživanje, b) motivi hrane snimljeni za istraživanje i c) motivi pejzaža snimljeni za istraživanje

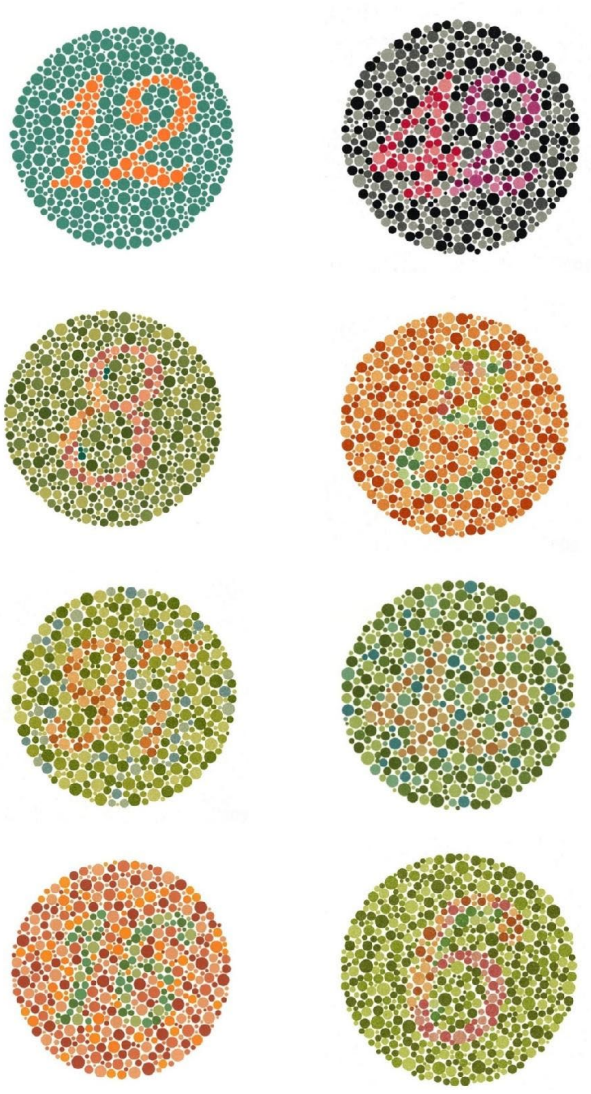
Tako se dobiveni digitalni zapisi učitavaju u program za obradu Adobe Photoshop te se, kao i standardna tablica boja, obrađuju promjenama vrijednosti plavog, zelenog i crvenog kanala (Slika 45). Svaki digitalni zapis fotografije sastoji se od crvenog, plavog i zelenog kanala, a promjene svakog od kanala rađene su za svaku fotografiju zasebno u koracima od -3%, -6%, -9%, -12%, 3%, 6%, 9% i 12%. Da bi se to moglo napraviti bilo je potrebno svaku fotografiju podesiti u svakom od kanala (plavog, zelenog i crvenog) i u svakom kanalu provesti promjenu za sve navedene postotke.


a)


b)

Slika 45 Primjer stvaranja promjene na primjeru fotografije dječjeg portreta: a) od -3% u crvenom kanalu i b) od -12% u plavom kanalu

Za vizualne se procjene odabiru dvije skupine ispitanika, skupina ispitanika-eksperata – stručnjaka iz područja primjene fotografije i skupina ispitanika-konzumenata – ispitanika bez direktnog iskustva u području primjene fotografije, ali s interesom prema vizualnim komunikacijama. Vizualne se procjene provode temeljem fotografskih slika realiziranih na kalibriranim izlaznim jedinicama u standardnim uvjetima promatranja (ISO 3664 : 2009)[65]. Svi ispitanici prolaze Ishihara test raspoznavanja boja (Slika 46).



Slika 46 Ishihara test raspoznavanja boja

Ishihara test raspoznavanja boja osmislio je Shinobu Ishihara za sljepoću na prvenstveno crveno-zeleni dio spektra 1917. godine. Test se sastoji od nekoliko (10, 14, 24, 48) kartica s nacrtanim kružnim oblikom ispunjenim točkastim uzorkom različitih veličina točkica i obojenja. Unutar svakog kružnog oblika nalazi se broj kojeg treba raspoznati. U slučaju ne

prepoznavanja boja radi se o nekom obliku sljepoće na boje. Osim papirnatih kartica boje koje se gledaju pod standardnim uvjetima promatranja, danas postoje i online testovi raspoznavanja boja, a jedan od njih nalazi se na stranici https://www.hr.colorlitelens.com/test-daltonizma.html gdje se od ispitanika traži da na 14 uzoraka označi prazninu unutar nacrtanog kruga te prema tome određuje postoji li prisutan daltonizam, te ako postoji koju vrstu daltonizma osoba ima i u kojem postotku prema riješenom testu.. Razlikuju nekoliko vrsta različitih sljepoća na boje u svojim testovima i to su: crveno-zeleni test za protanopija/deuteranopija kolor slijepe, ljubičasto-plavi test za osobe s protanopijom, ljubičasto-zeleni ili tzv. „Deutan“ test za osobe s deuteranopijom te crveno-ljubičasti ili tzv. „Tritan“ test za osobe s tritanopijom. Test je nužan kako bi se osiguralo gledanje uzoraka osobama bez teškoća kod raspoznavanja boja. Zbog malih promjena boja koje su rađene na uzorcima za ispitivanje istraživanju su mogle pristupiti osobe sa 100% riješenim testom.

Pri ispitivanju skupina ispitanika u istraživanju se koriste tri metode prikupljanja podataka. Za prikupljanje općih podataka o ispitanicima se koristi nominalna ljestvica koja prikuplja podatke i obilježja kao što su naziv, ime ili kategorija bez računskih operacija. Pri odabiru testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničnosti i procjeni mogućnosti optimalnog zadržavanja ikoničkog karaktera u metamerijskim uvjetima konzumacije se koriste ordinalne ljestvice kojima se fotografske slike rangiraju s obzirom na zadani kriterij u odnosu na početnu fotografsku sliku, odnosno sliku konzumiranu u optimalnim uvjetima rasvjete. Kod ordinalne ljestvice također nema računskih operacija, ali se vrijednosti međusobno mogu uspoređivati. Pri procjeni interpretacije testnih fotografskih slika koristi se Likertova ljestvica kao ljestvica mjerenja stava koja ispitanicima daje mogućnost određivanja stupnja slaganja s ponuđenom interpretacijom fotografske slike. Procjena se najčešće daje tako da svaku tvrdnju prati pet mogućih odgovora (potpuno slaganje, slaganje, neodlučnost/neutralnost, neslaganje, potpuno neslaganje). Kod ispitivanja skupine ispitanika ordinalnom ljestvicom se koristi simultano binokularno usaglašavanje koje daje najusporedivije rezultate s primijenjenim mjernim metodama, a kod ispitivanja Likertovom ljestvicom memorijsko usaglašavanje koje simulira realne uvjete konzumacije fotografske slike. [23][66][67] Rezultati eksperimenta se detaljno statistički obrađuju, što uključuje deskriptivnu statističku analizu svih dobivenih uzoraka kao i provjeru usklađenosti svih podataka sa zakonom normalne razdiobe.
Za dobivene se digitalne zapise određuju L, a i b vrijednosti boja iz kojih se računaju ukupne razlike boja te se analiziraju histogrami fotografskih slika.

Kako dosadašnja istraživanja dokazuju mogućnost upravljanja percepcijom, a time i interpretacijom fotografske slike promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa, ali ukazuju i da među tim varijablama postoji odgovarajući oblik povezanosti, za određivanje njihove korelacije se u istraživanju koristi Spearmanov koeficijent korelacije [68]. Spearmanov koeficijent korelacije koristi se u slučajevima kada linearni oblik povezanosti nije bitan, a mjeri dosljednost povezanosti između poredanih varijabli.
Ovisno za istraživanjem utvrđen oblik povezanosti izrađuju se odgovarajući linearni ili nelinearni regresijski modeli te se dobivaju analitički izrazi koji omogućavaju procjenu utjecaja sva tri kanala digitalnog zapisa na percepciju fotografske slike. Sve hipoteze koje se dokazuju ovim istraživanjem se provjeravaju odgovarajućim statističkim testovima.
U skladu s navedenim, tijek istraživanja je podijeljen u šest faza.

3.2. Prva faza: Realizacija testnih fotografskih slika

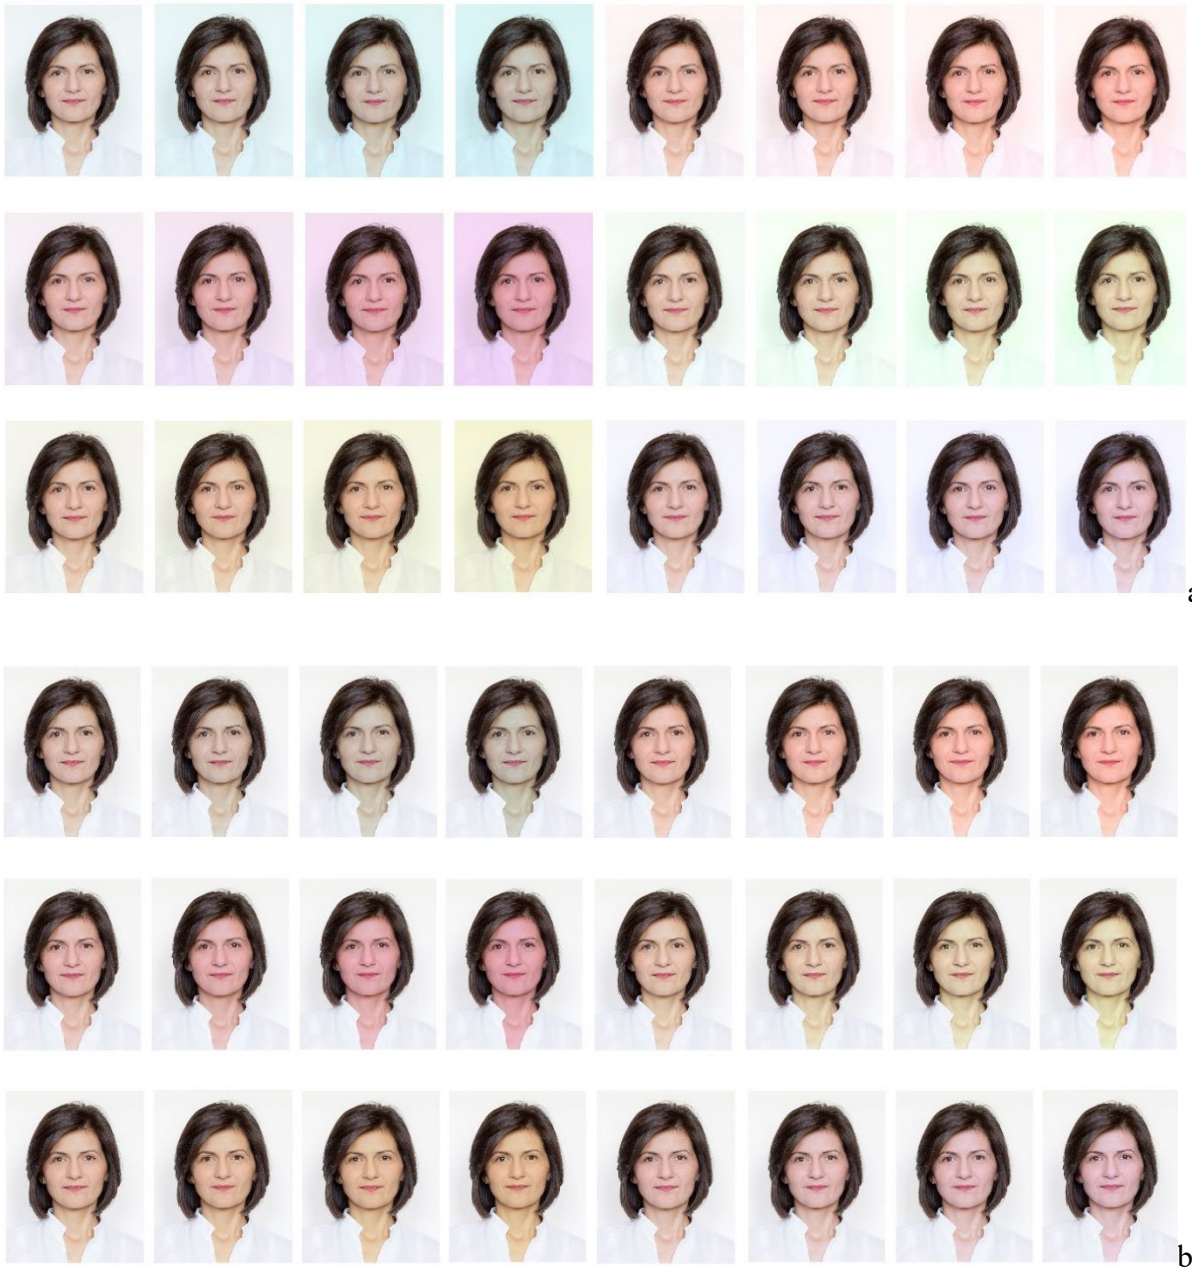
Za potrebe ispitivanja se snimanjem i obradom realiziraju testne fotografije. Snimljene su po tri, po karakteristikama boja, sintaktički karakteristične portretne, pejzažne i fotografije hrane. (Slika 44) Za motive portreta snimljene su fotografije muškog, ženskog i dječjeg portreta, za motive pejzaža pejzaž s prevladavajućom bojom, pejzaž s prigušenim bojama i pejzaž izrazitih boja. Za motive hrane snimljene su fotografija ručka, fotografija povrća i fotografija voća. Sve navedene fotografije snimljene su u digitalnom fotografskom sustavu fotografskim aparatom Canon EOS 5D Mark III [69]u kojem se definiraju digitalni zapisi u najfinijem (12) JPEG zapisu u Adobe RGB prostoru boja uz tehnički korektne elemente ekspozicije i odgovarajući bijeli balans.
Digitalni zapisi tako dobivenih fotografskih slika se uz percepcijsko renderiranje prebacuju u sRGB prostor boja kao standardni reproducibilni prostor boja za izlazne fotografske jedinice [70]. Digitalni se zapisi obrađuju promjenama vrijednosti plavog, zelenog i crvenog kanala zapisa u granicama +/- 12% uz korak promjene 3% na cijelim površinama i na odabranim karakterističnim selekcijama, ovisno o sintaktičkim postavkama konkretne fotografske slike. Sve fotografije obrađene su u Adobe Photoshop programu za obradu slika [64].

3.2.1. Portret

Za motiv portreta snimljeni su portret žene, portret muškarca i portret djeteta. (Slika 44)
Svaka od fotografija obrađena je promjenama oslabljivanjem i pojačavanjem crvenog, zelenog i plavog kanala u koracima od 3, 6, 9 i 12%. Portreti su snimljeni prema standardima za biometrijski portret [71] korištenjem krupnog plana. Kod portreta svi portreti obrađeni su za

sve varijacije kanala na cijeloj površini slike i samo na selekciji lica zbog karakteristične boje kože lica i sintaktičkih postavki fotografije karakterističnih za portret.

Fotografije ženskog portreta prikazuju sve fotografije napravljene na cijeloj površini fotografije (PŽ) i na selekciji lica (PŽS) uz sve varijacije oslabljivanja i pojačavanja svih kanala prije pripreme za odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera u odnosu na original u drugoj fazi istraživanja. (Slika 47)



a)

b)

Slika 47 Fotografije ženskog portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PŽ) i b) na selekciji lica (PŽS)

Fotografije s motivom muškog portreta prikazuju sve fotografije napravljene na cijeloj površini fotografije (PM) i na selekciji lica (PMS) uz sve varijacije oslabljivanja i pojačavanja svih kanala prije pripreme za odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera u odnosu na original u drugoj fazi istraživanja. (*Slika 48*)



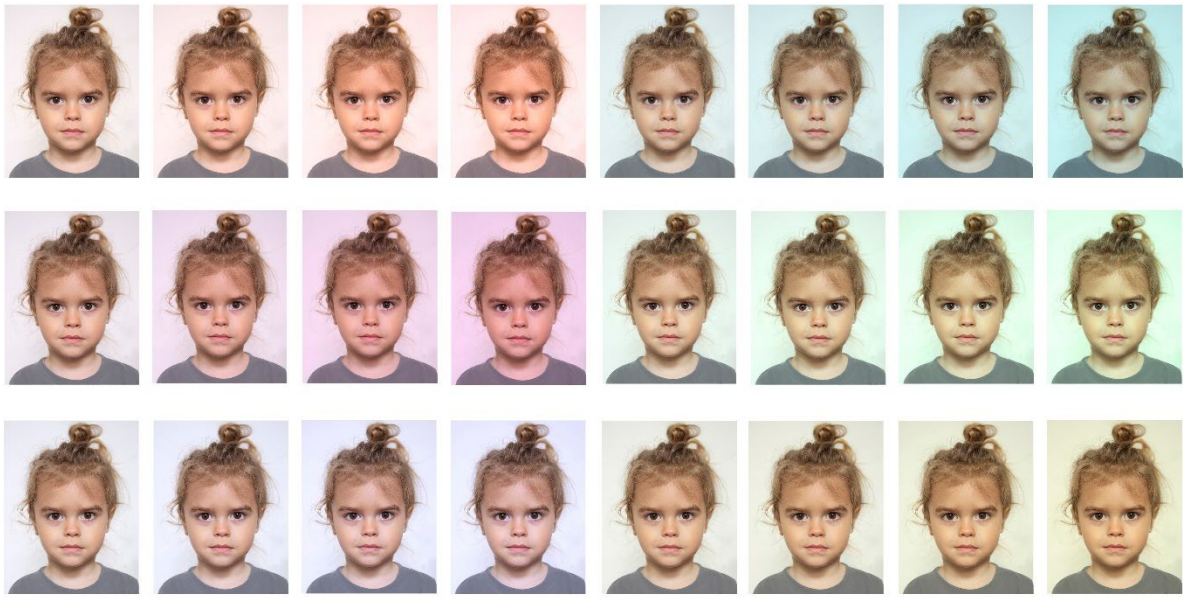
a)

b)

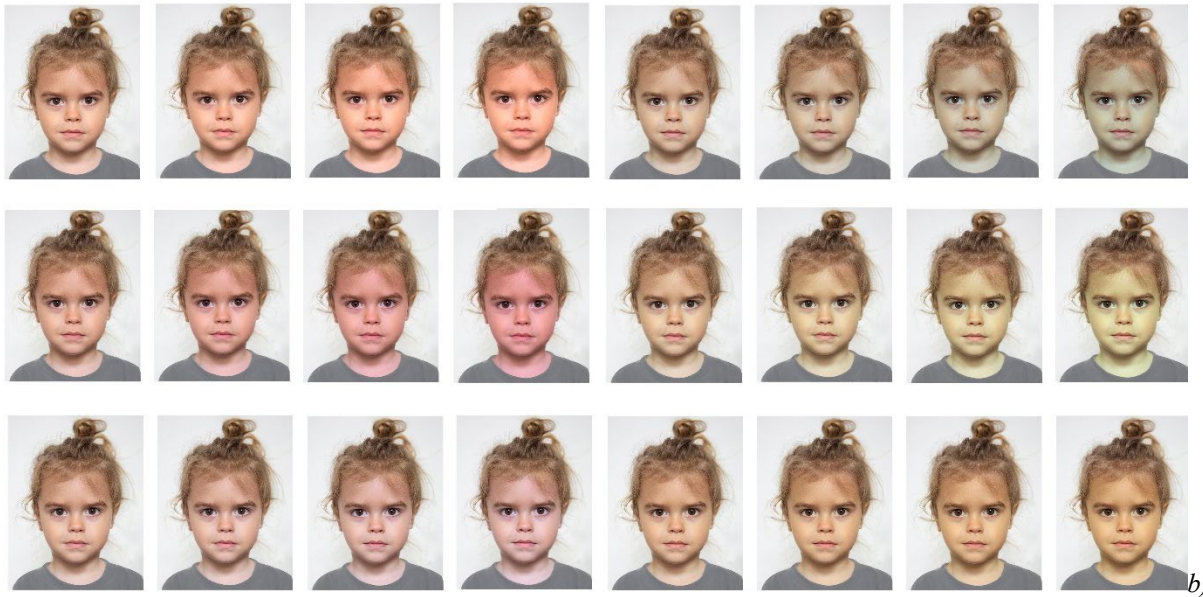
Slika 48 Fotografije muškog portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PM) i b) na selekciji lica (PMS)

Fotografije s motivom dječjeg portreta prikazuju sve promjene napravljene na cijeloj površini fotografije (PD) i na selekciji lica (PDS) uz sve varijacije oslabljivanja i pojačavanja svih kanala prije pripreme za odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog

karaktera u odnosu na original u drugoj fazi istraživanja. (*Slika 49*)



a)



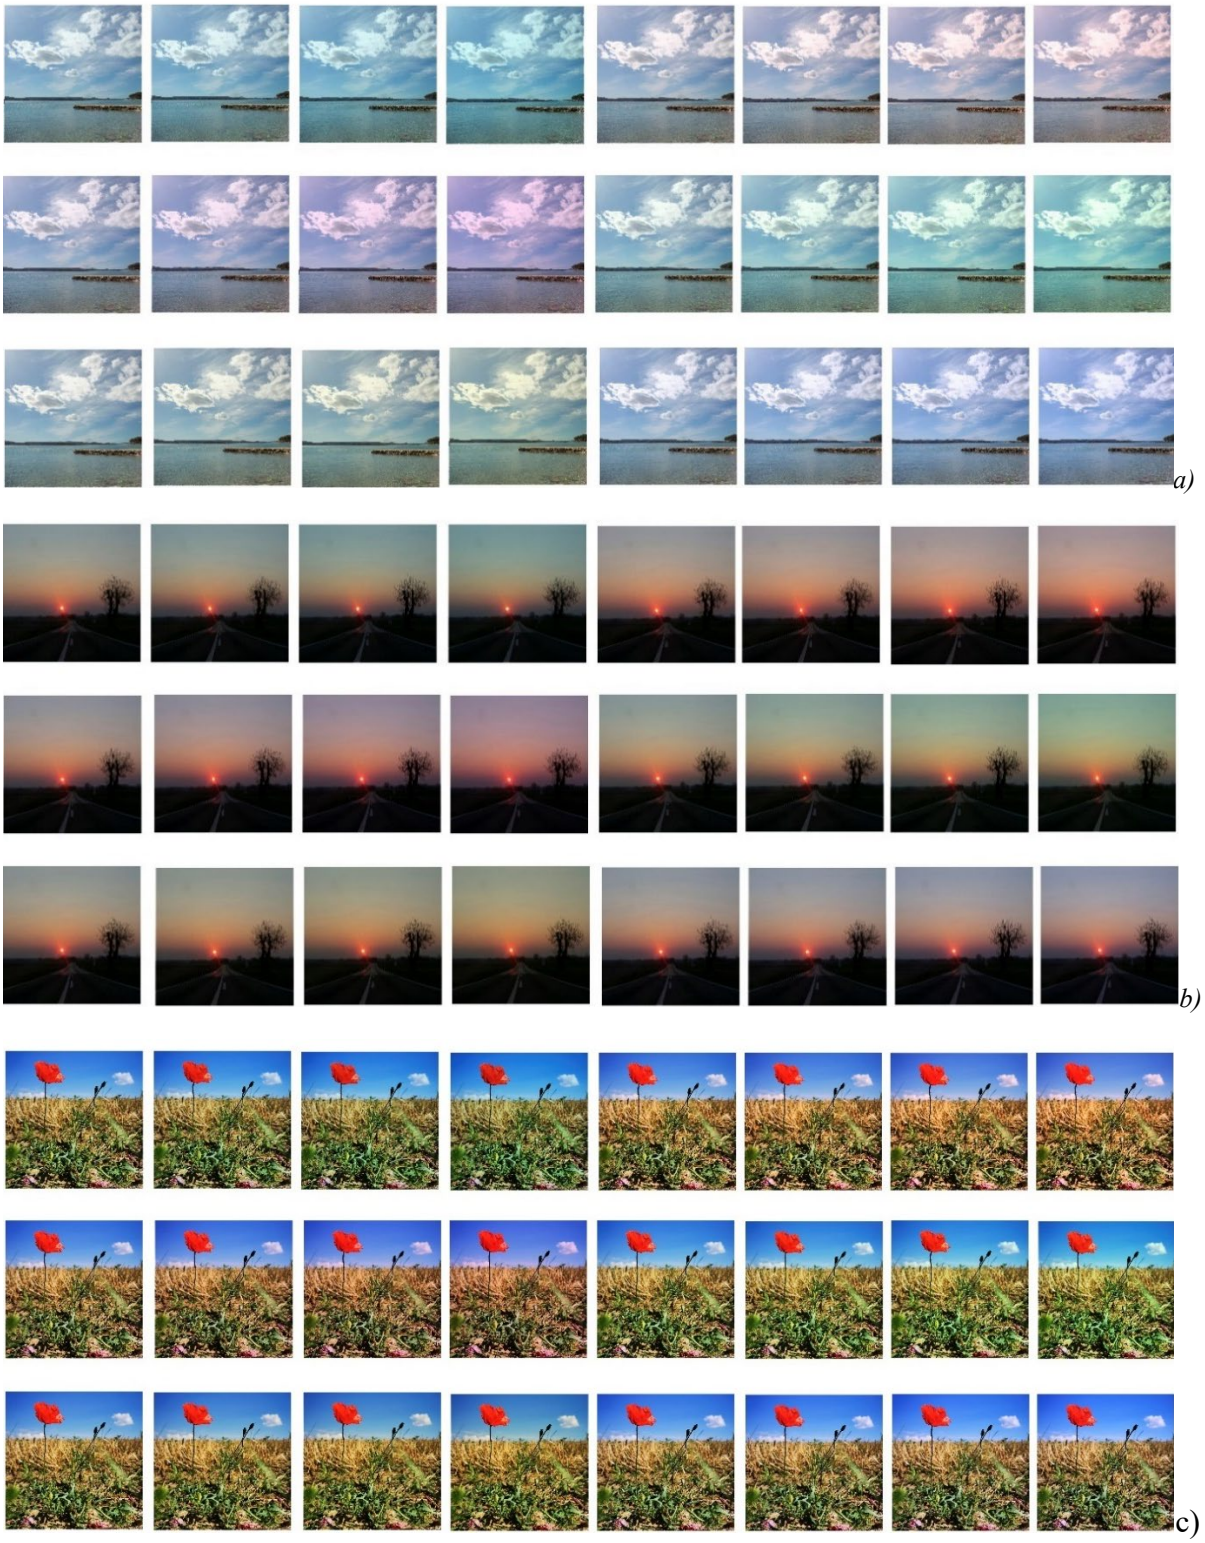
b)

Slika 49 Fotografije dječjeg portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PD) i b) na selekciji lica (PDS)

3.2.2. Pejzaž

Za motive pejzaža odabrani su klasičan morski pejzaž (LA), zalazak sunca s prigušenim tonovima (LB) te jarki pejzaž ljetnog polja s izrazitim bojama (LC). Pejzaži LA i LB snimljeni su koristeći plan total, a pejzaž LC snimljen je koristeći srednji plan. Na fotografijama pejzaža u doktorskom radu prema sintaktičkim postavkama korišten je tzv. format 6x6, pravilo trećine te su korišteni sklad boja za pejzaž LA, prigušene boje za pejzaž LB i izrazite boje za pejzaž LC. Uz ove sintaktičke postavke kod fotografija pejzaža te općenito zato što to sam motiv ne

traži nisu rađene promjene na selekcijama određenih boja/dijelova motiva već su promjene napravljene na cijelim površinama fotografskih slika pejzaža. Fotografije s motivom pejzaža LA, LB i LC prikazuju sve varijacije oslabljivanja i pojačavanja svih kanala prije pripreme za odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera u odnosu na original u drugoj fazi istraživanja. (Slika 50).



Slika 50 Fotografije s 24 varijacije po svim kanalima: a) pejzaž LA, b) pejzaž LB i c) pejzaž LC

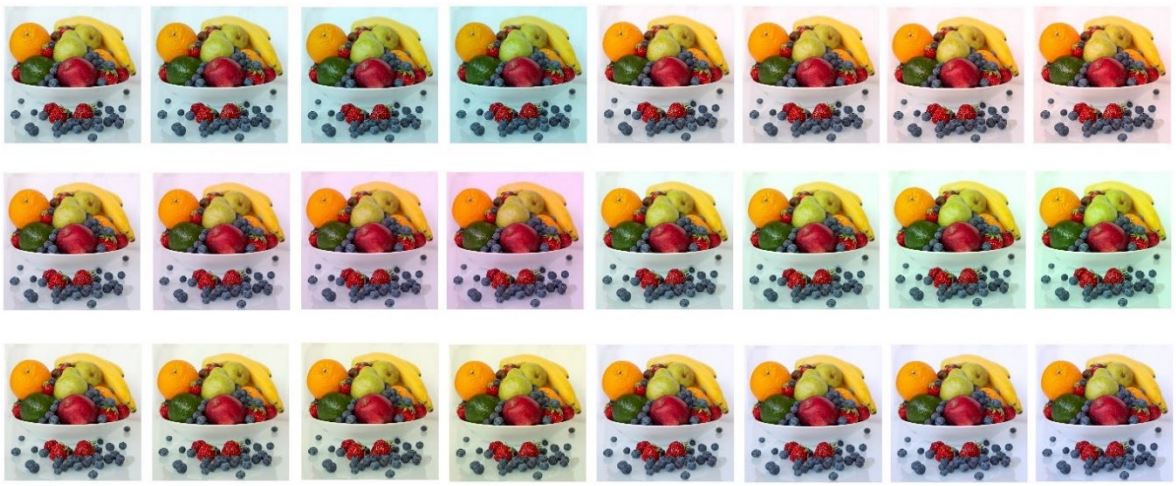
3.2.3. Fotografija hrane

Za fotografiju hrane odabrana su tri motiva, jelo neutralnih tonova (HA) te fotografija povrća (HB) i fotografija voća (HC) raznolikih boja. Fotografije hrane snimljene su korištenjem blizog plana. Kod motiva fotografija hrane fotografije su izrađene u tzv. 6x6 formatu, a s obzirom na to da motivi dopuštaju odabir i promjenu i selekcije uz cijelu površinu slike, za motive hrane HA i HC napravljene su izmjene na cijeloj površini fotografije, dok su na motivima HB i HC napravljene izmjene na selekciji hrane bez utjecaja na ostatak motiva (pozadina ili posuda u kojoj se hrana nalazi).

Fotografije u nastavku prikazuju sve fotografije s motivom hrane i svim varijacijama oslabljivanja i pojačavanja svih kanala prije pripreme za odabir prema kriteriju zadržavanja ikoničnosti u odnosu na original i odabir testnih fotografija koje zadržavaju ikoničnost i koje će ići dalje u istraživanje. (Slika 51, Slika 52)



Slika 51 Fotografije s 24 varijacije po svim kanalima za a) hranu A s promjenom na cijeloj površini slike, b) hranu B s promjenom samo na selekciji slike


a)


b)

Slika 52 Fotografije sa 24 varijacije po svim kanalima za a) hranu C s promjenom na cijeloj površini slike i b) hranu C s promjenom samo na selekciji slike

3.3. Druga faza: Odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera

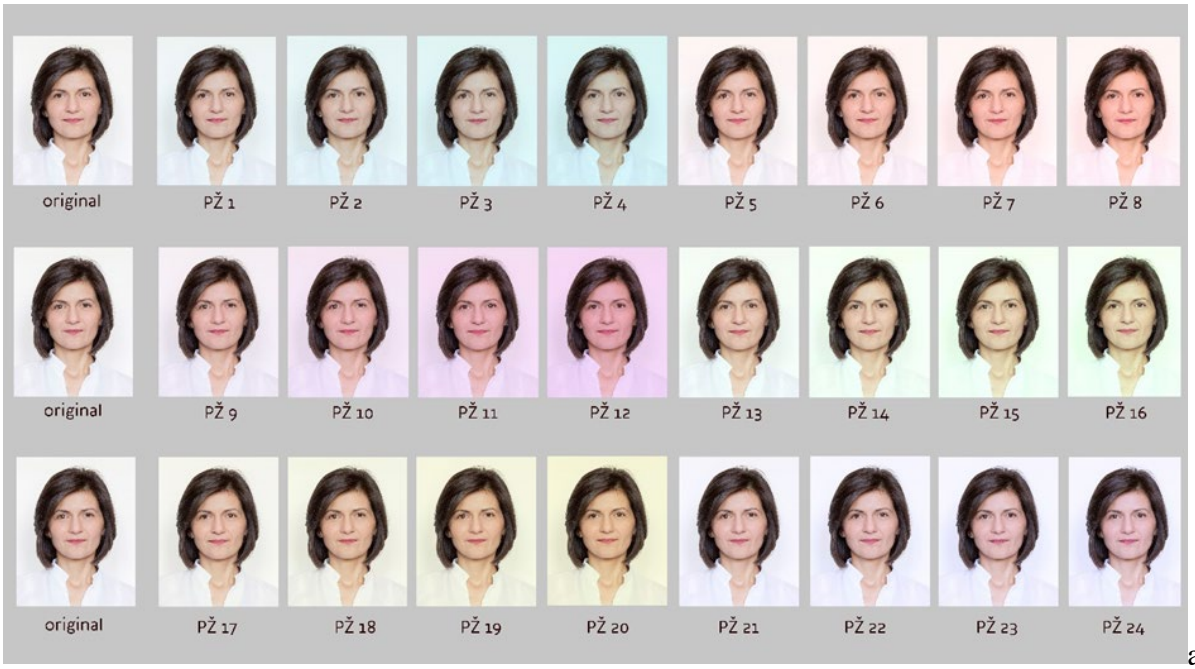
U ovoj fazi odabiru se testne fotografske slike pojedinih motiva koje ispunjavaju zahtjev zadržavanja ikoničkog karaktera konkretne fotografske slike. Kako bi se ispitivanje moglo provesti sve testne fotografije s varijacijama na cijeloj površini slike i samo na određenim selekcijama sukladno sintaktičkim i semantičkim zahtjevima pojedinog motiva dobile su svoju jedinstvenu šifru koja se sastojala od slova i brojki. (Tablica 2)

Ženskom portretu pridodana je osnovna šifra PŽ, ženskom portretu sa selekcijom PŽS, muškom portretu MP, muškom portretu sa selekcijom MPS, dječjem portretu DP, dječjem portretu sa selekcijom DPS, morskom pejzažu LA, pejzažu sa zalaskom sunca LB, pejzažu polja s izrazitim bojama LC, fotografiji ručka HA, fotografiji povrća sa selekcijom HBS, fotografiji voća HC i fotografiji voća sa selekcijom HCS. Fotografije su pripremljene na neutralnoj sivoj podlozi u veličini ekrana na kojem se obavljala procjena.

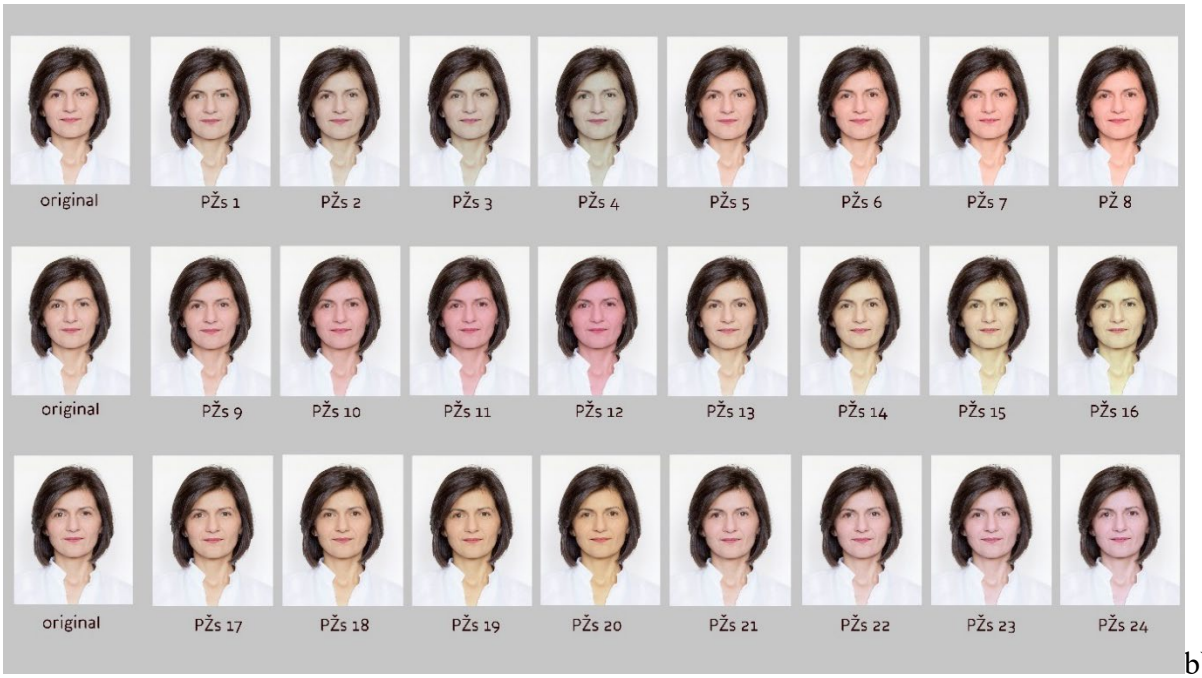
Tablica 2 Motivi fotografija i dodijeljene šifre za svaki motiv i njegovu varijaciju za svaki kanal

Motiv	Šifra motiva	Original	Varijacije																							
			R								G								B							
			-3	-6	-9	-12	+3	+6	+9	+12	-3	-6	-9	-12	+3	+6	+9	+12	-3	-6	-9	-12	+3	+6	+9	+12
Ženski portret	PŽ	PŽ0	PŽ 1	PŽ 2	PŽ 3	PŽ 4	PŽ 5	PŽ 6	PŽ 7	PŽ 8	PŽ 9	PŽ 10	PŽ 11	PŽ 12	PŽ 13	PŽ 14	PŽ 15	PŽ 16	PŽ 17	PŽ 18	PŽ 19	PŽ 20	PŽ 21	PŽ 22	PŽ 23	PŽ 24
Ženski portret sa selekcijom lica	PŽS	PŽS 0	PŽS 1	PŽS 2	PŽS 3	PŽS 4	PŽS 5	PŽS 6	PŽS 7	PŽS 8	PŽS 9	PŽS 10	PŽS 11	PŽS 12	PŽS 13	PŽS 14	PŽS 15	PŽS 16	PŽS 17	PŽS 18	PŽS 19	PŽS 20	PŽS 21	PŽS 22	PŽS 23	PŽS 24
Muški portret	PM	PM0	PM 1	PM 2	PM 3	PM 4	PM 5	PM 6	PM 7	PM 8	PM 9	PM 10	PM 11	PM 12	PM 13	PM 14	PM 15	PM 16	PM 17	PM 18	PM 19	PM 20	PM 21	PM 22	PM 23	PM 24
Muški portret sa selekcijom lica	PMS	PMS 0	PMS 1	PMS 2	PMS 3	PMS 4	PMS 5	PMS 6	PMS 7	PMS 8	PMS 9	PMS 10	PMS 11	PMS 12	PMS 13	PMS 14	PMS 15	PMS 16	PMS 17	PMS 18	PMS 19	PMS 20	PMS 21	PMS 22	PMS 23	PMS 24
Dječji portret	PD	PD0	PD 1	PD 2	PD 3	PD 4	PD 5	PD 6	PD 7	PD 8	PD 9	PD 10	PD 11	PD 12	PD 13	PD 14	PD 15	PD 16	PD 17	PD 18	PD 19	PD 20	PD 21	PD 22	PD 23	PD 24
Dječji portret sa selekcijom lica	PDS	PDS 0	PDS 1	PDS 2	PDS 3	PDS 4	PDS 5	PDS 6	PDS 7	PDS 8	PDS 9	PDS 10	PDS 11	PDS 12	PDS 13	PDS 14	PDS 15	PDS 16	PDS 17	PDS 18	PDS 19	PDS 20	PDS 21	PDS 22	PDS 23	PDS 24
Morski pejzaž	LA	LA0	LA1	LA2	LA3	LA4	LA5	LA6	LA7	LA8	LA9	LA 10	LA 11	LA 12	LA 13	LA 14	LA 15	LA 16	LA 17	LA 18	LA 19	LA 20	LA 21	LA 22	LA 23	LA 24
Pejzaž sa zalaskom sunca	LB	LB0	LB1	LB2	LB3	LB4	LB5	LB6	LB7	LB8	LB9	LB 10	LB 11	LB 12	LB 13	LB 14	LB 15	LB 16	LB 17	LB 18	LB 19	LB 20	LB 21	LB 22	LB 23	LB 24
Pejzaž ljetnog polja izrazitih boja	LC	LC0	LC1	LC2	LC3	LC4	LC5	LC6	LC7	LC8	LC9	LC 10	LC 11	LC 12	LC 13	LC 14	LC 15	LC 16	LC 17	LC 18	LC 19	LC 20	LC 21	LC 22	LC 23	LC 24
Fotografija hrane ručka	HA	HA0	HA1	HA2	HA3	HA4	HA5	HA6	HA7	HA8	HA9	HA 10	HA 11	HA 12	HA 13	HA 14	HA 15	HA 16	HA 17	HA 18	HA 19	HA 20	HA 21	HA 22	HA 23	HA 24
Fotografija povrća sa selekcijom i varijacijama samo na povrću	HBS	HBS 0	HBS 1	HBS 2	HBS 3	HBS 4	HBS 5	HBS 6	HBS 7	HBS 8	HBS 9	HBS 10	HBS 11	HBS 12	HBS 13	HBS 14	HBS 15	HBS 16	HBS 17	HBS 18	HBS 19	HBS 20	HBS 21	HBS 22	HBS 23	HBS 24
Fotografija voća s varijacijama na cijeloj površini slike	HC	HC0	HC1	HC2	HC3	HC4	HC5	HC6	HC7	HC8	HC9	HC 10	HC 11	HC 12	HC 13	HC 14	HC 15	HC 16	HC 17	HC 18	HC 19	HC 20	HC 21	HC 22	HC 23	HC 24
Fotografija voća sa selekcijom i varijacijama samo na voću	HCS	HCS 0	HCS 1	HCS 2	HCS 3	HCS 4	HCS 5	HCS 6	HCS 7	HCS 8	HCS 9	HCS 10	HCS 11	HCS 12	HCS 13	HCS 14	HCS 15	HCS 16	HCS 17	HCS 18	HCS 19	HCS 20	HCS 21	HCS 22	HCS 23	HCS 24

Pripremljeni su setovi fotografija na neutralnoj sivoj podlozi s testnim fotografskim slikama te označeni odgovarajućim šiframa. Ukupno je pripremljeno 13 setova fotografija od čega se svaki set sastojao od originalnih fotografija i 24 varijacije svakog motiva ovisno o njegovim sintaktičkim i semantičkim postavkama za usporedbu simultanim binokularnim usuglašavanjem. U ovoj fazi eksperti su ukupno pregledali 312 varijacija fotografija u 13 setova. Nakon svakog seta fotografija bila je predviđena pauza. Prva dva seta iz serije portreta čini ženski portret s varijacijama na cijeloj površini i samo na selekciji lica (Slika 53 a i b).



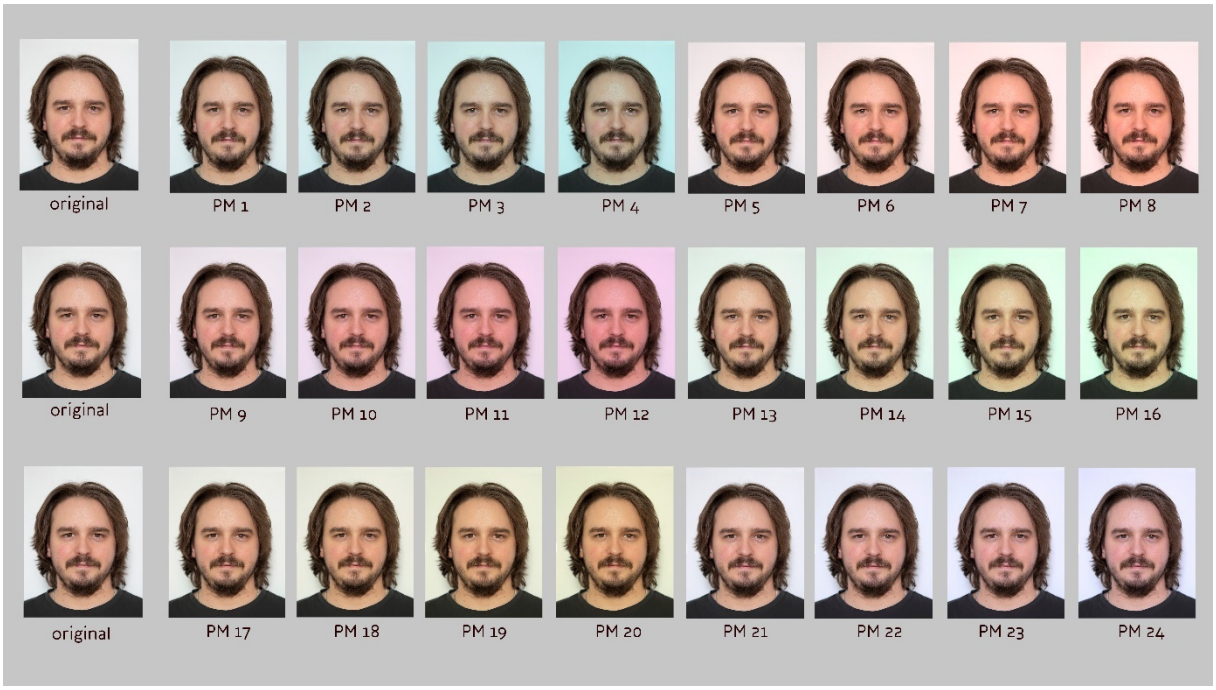
a)



b)

Slika 53 Set fotografija ženskog portreta pripremljen za gledanje ekspertima: a) s varijacijom na cijeloj površini digitalnog zapisa slike i b) sa varijacijom na selekciji lica

Treći set iz serije portreta bio je muški portret s varijacijama na cijeloj površini digitalnog zapisa (Slika 54), a četvrti set bio je muški portret s varijacijama izvedenim samo na selekciji lica. (Slika 55).

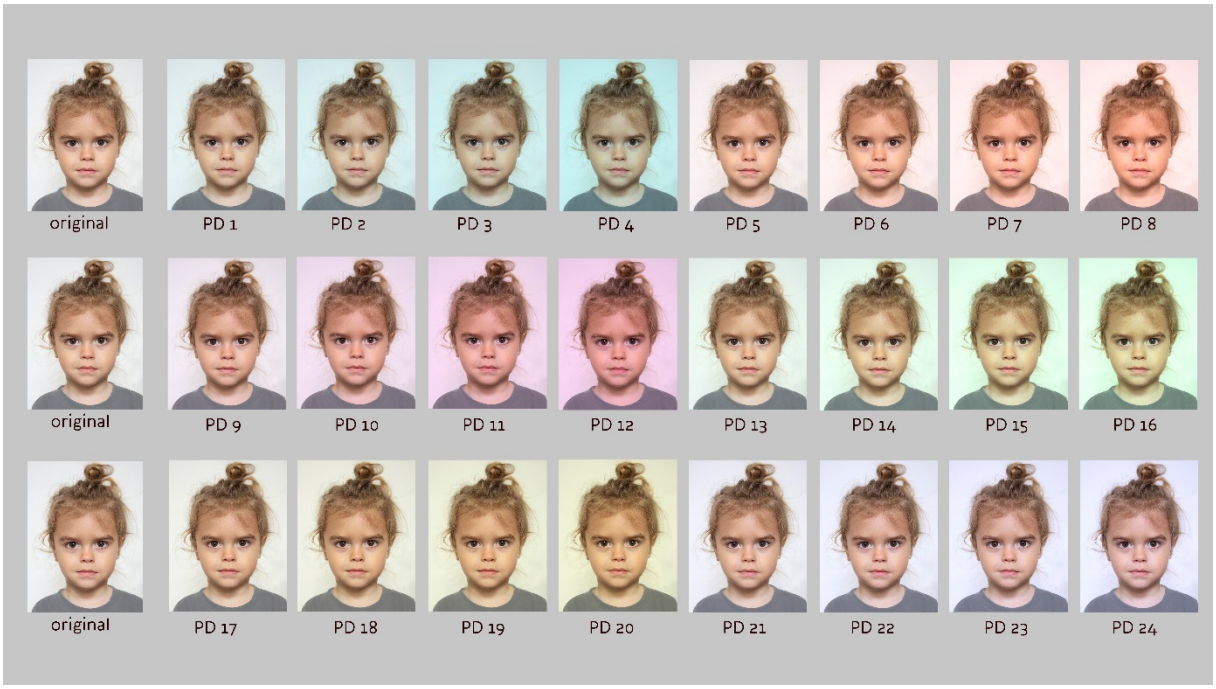


Slika 54 Set fotografija varijacija muškog portreta (PM) pripremljen za gledanje ekspertima

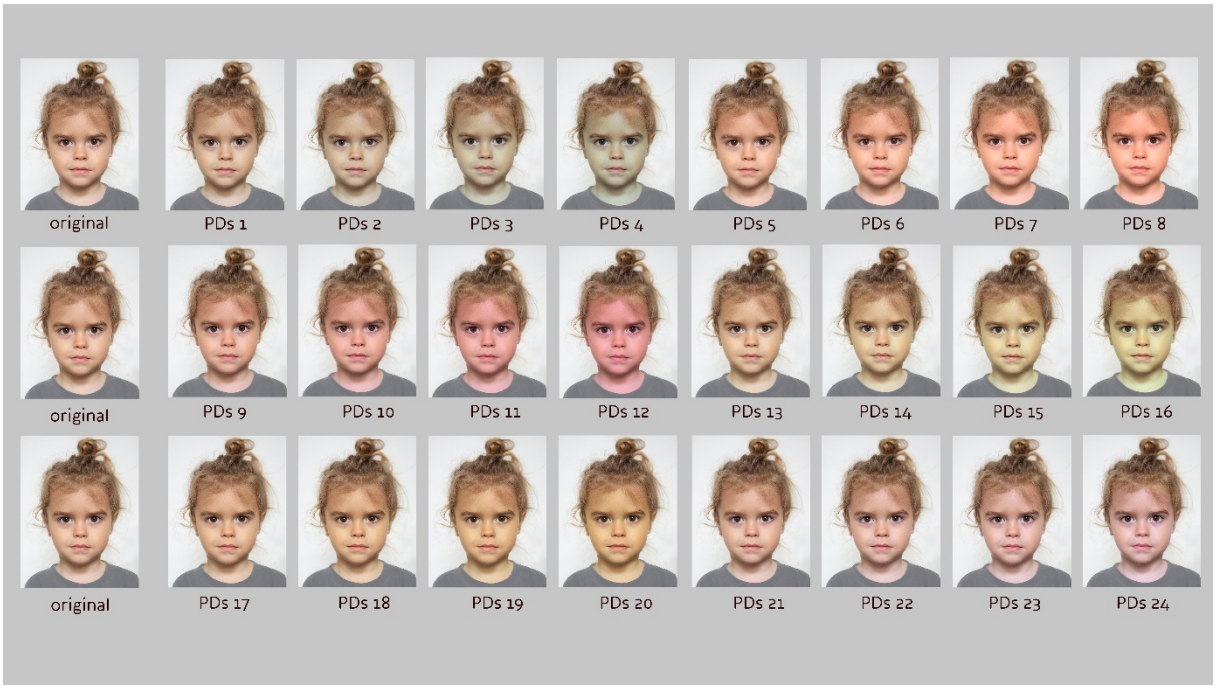


Slika 55 Set fotografija varijacija muškog portreta sa selekcijom (PMS) pripremljen za gledanje ekspertima

Peti set pripremljen ekspertima za gledanje iz serije portreta bio je dječji portret s varijacijama na cijeloj površini digitalnog zapisa slike (Slika 56), a šesti set dječji portret s varijacijama izvedenim samo na selekciji lica. (Slika 57)

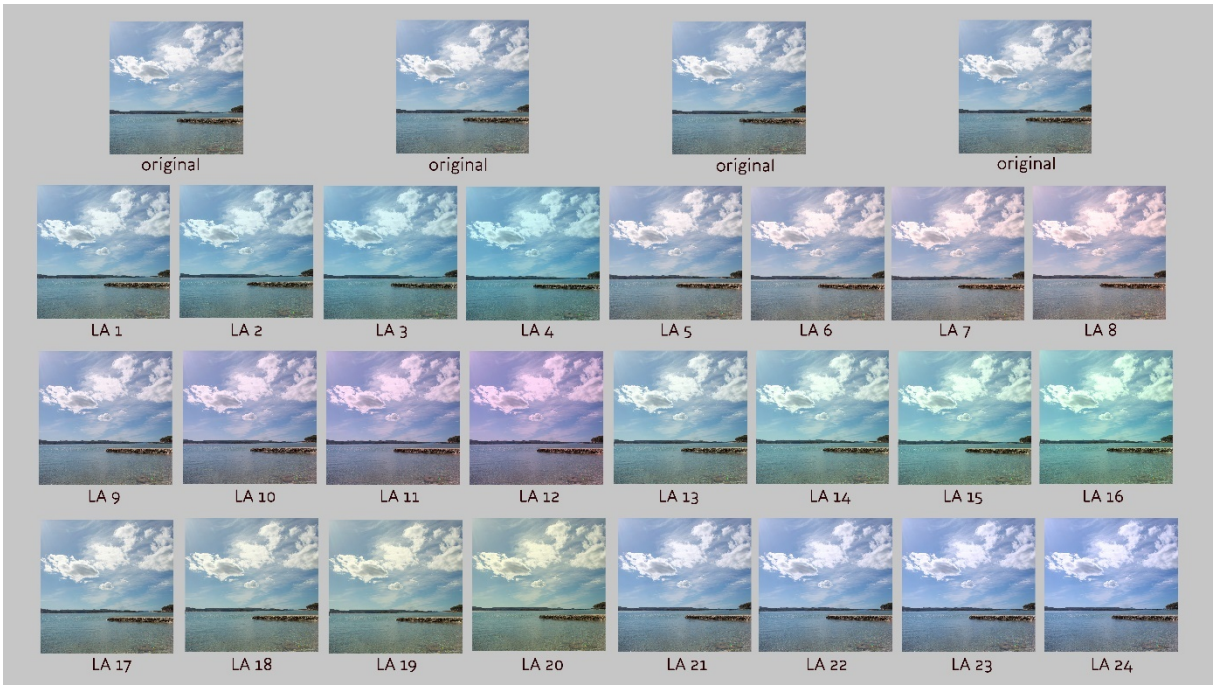


Slika 56 Set fotografija varijacija dječjeg portreta pripremljen za gledanje ekspertima



Slika 57 Set fotografija varijacija dječjeg portreta sa selekcijom lica pripremljen za gledanje ekspertima

Sedmi set fotografija pripremljen za gledanje ekspertima je fotografija morskog pejzaža s prevladavajućom bojom (LA) s varijacijama na cijeloj površini digitalnog zapisa (Slika 58), a osmi set čini fotografija pejzaža zalaska sunca (LB) s varijacijama također na cijeloj površini digitalnog zapisa. (Slika 59)



Slika 58 Set fotografija varijacija morskog pejzaža (LA) pripremljen za gledanje ekspertima



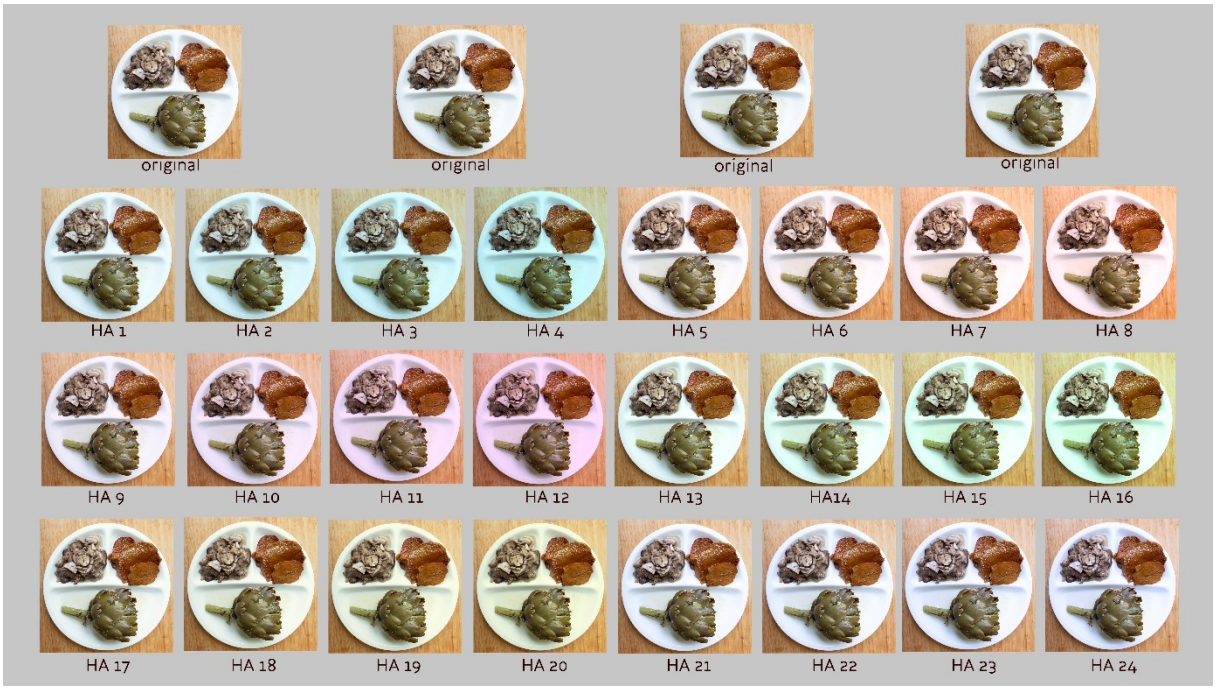
Slika 59 Set fotografija varijacija pejzaža zalaska sunca (LB) pripremljen za gledanje ekspertima

Deveti set čini fotografija pejzaža polja s izrazitim bojama (LC) s varijacijama na cijeloj površini digitalnog zapisa. (Slika 60) Svi motivi pejzaža imali su varijacije izvedene samo na cijeloj površini digitalnog zapisa slike.



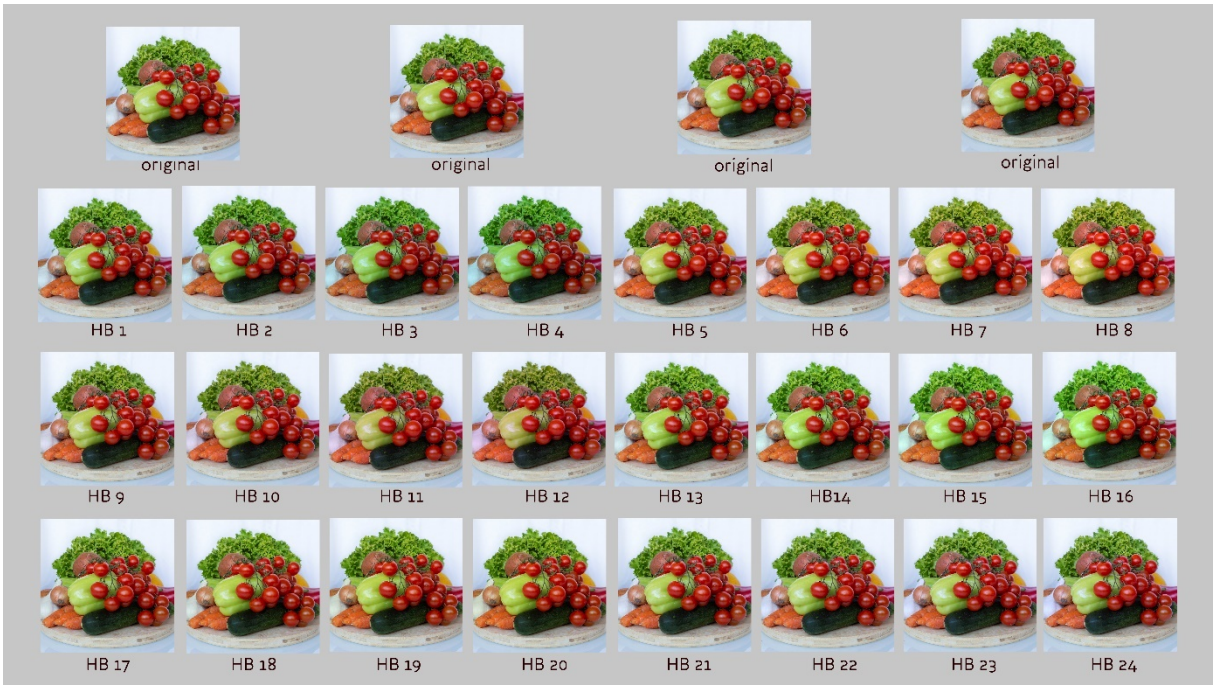
Slika 60 Set fotografija s varijacijama pejzaža polja s izrazitim bojama (LB) pripremljen za gledanje ekspertima

Deseti set čini fotografija hrane ručka s neutralnim bojama (HA) s varijacijama na cijeloj površini digitalnog zapisa. (Slika 61) Ova fotografija imala je varijacije samo na cijeloj površini digitalnog zapisa slike.



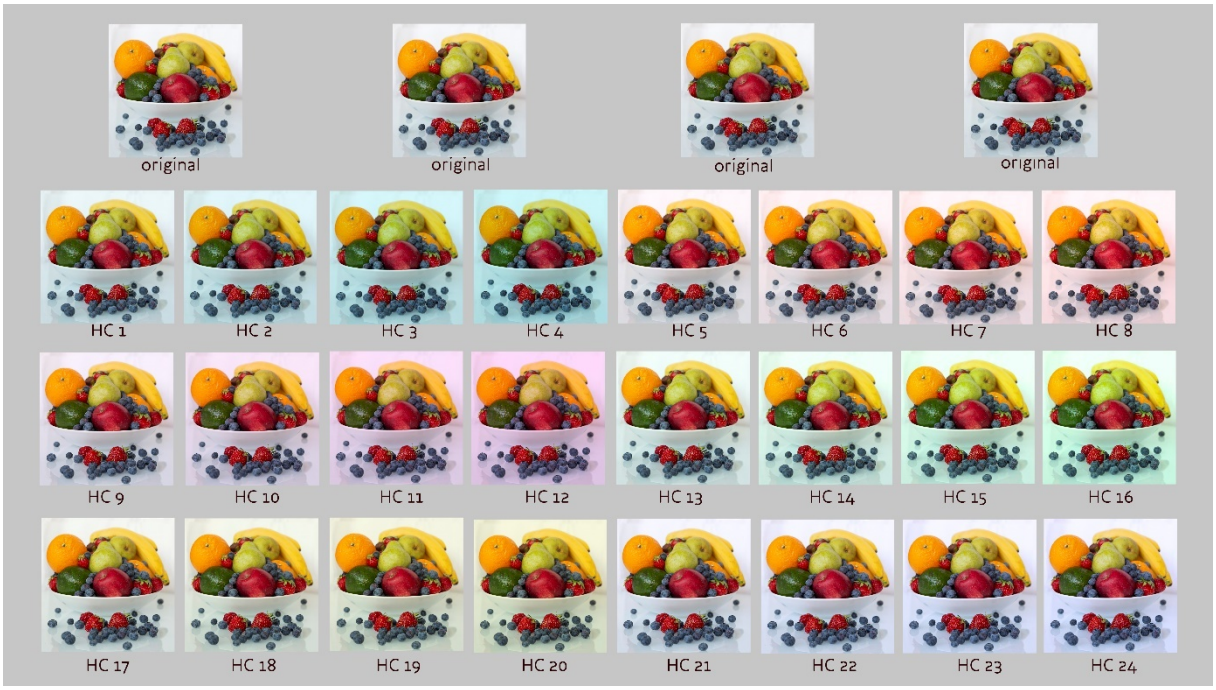
Slika 61 Set fotografija hrane ručka (HA) s varijacijama na cijeloj površini pripremljen za gledanje ekspertima

Jedanaesti set čini fotografija hrane povrća sa selekcijom (HBS) s varijacijama na odabranom dijelu površine digitalnog zapisa. (Slika 62) Ova fotografija imala je samo varijaciju na selekciji digitalnog zapisa.



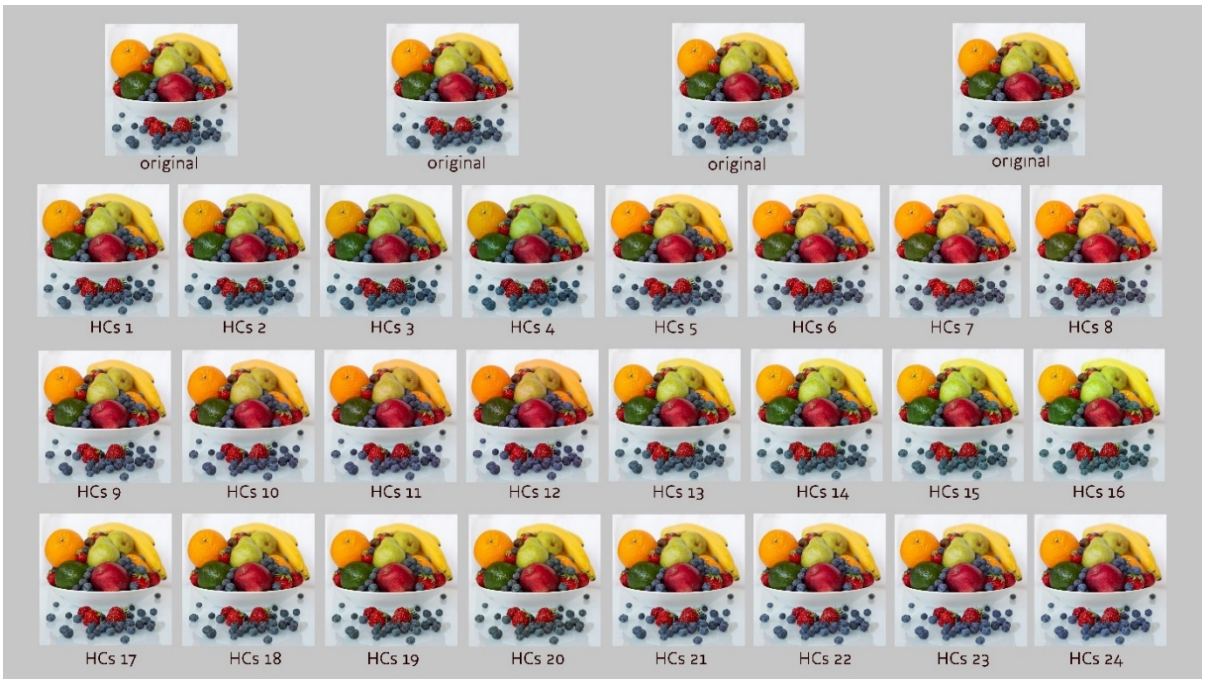
Slika 62 Set varijacija s fotografijom hrane povrća sa selekcijom (HBS) pripremljen za gledanje ekspertima

Dvanaesti set fotografija čini motiv hrane voća (HC) s varijacijom na cijeloj površini digitalnog zapisa. (Slika 63)



Slika 63 Set fotografija varijacija fotografija hrane C pripremljen za gledanje ekspertima

Trinaesti i ujedno posljednji set fotografija čini motiv hrane voća sa selekcijom (HCS) s varijacijama na odabranoj površini digitalnog zapisa. (Slika 64)



Slika 64 Set varijacija fotografija hrane voća sa selekcijom (HCS) pripremljen za gledanje ekspertima

Dimenzija gotovih fotografija prilagođena je veličini ekrana kako bi se osigurali uvjeti za neometano gledanje pripremljenih fotografija. Odabir se provodi ispitivanjem skupine ispitanika-eksperata primjenom ordinalne ljestvice metodom simultanog binokularnog usklađivanja na monitorima TCL 55"P615 4K Android TV. (Slika 65) [72][73][74]



Slika 65 Eksperti iz područja fotografije i vizualnih umjetnosti gledaju uzorke

Zadatak eksperata bio je rangirati fotografije prema stupnju zadržavanja ikoničkog karaktera, pri čemu je 1 najveći stupanj zadržavanja ikoničkog karaktera, a 24 je najmanji stupanj zadržavanja ikoničkog karaktera. Drugi zadatak eksperata za svaku fotografiju bio je odrediti za koje sve fotografije ikonički karakter više nije zadržan (Slika 65, Slika 66). Analizom rezultata ovog dijela eksperimenta izdvojene su fotografije koje prema ocjenama eksperata ne zadržavaju ikonički karakter te one nisu ušle u daljnju analizu. U ovom koraku izbačeno je ukupno 100 fotografija različitih varijacija od ukupno 312 varijacija za sve motive i kanale s i bez selekcija. (Tablica 2)

Istraživanje – doktorski rad – Pavlović Ivana

Obrazac za procjenu - eksperti

ŠIFRA:

SPOL:

DOB:

RADNO MJESTO (područje rada):

1. Zadatak

Molimo da prikazane fotografije **rangirate** s obzirom na **stupanj zadržavanja ikoničnosti karaktera** u odnosu na **original**.

U polje svake fotografije pridružite pripadajući rang (redno mjesto od 1. do 24.)

FOTOGRAFIJA: Portret ženski

RANG								
ŠIFRA	PŽ 1	PŽ 2	PŽ 3	PŽ 4	PŽ 5	PŽ 6	PŽ 7	PŽ 8

RANG								
ŠIFRA	PŽ 9	PŽ 10	PŽ 11	PŽ 12	PŽ 13	PŽ 14	PŽ 15	PŽ 16

RANG								
ŠIFRA	PŽ 17	PŽ 18	PŽ 19	PŽ 20	PŽ 21	PŽ 22	PŽ 23	PŽ 24

2. Zadatak

Molimo označite (zaokružite šifru) **svih** fotografija na kojima u odnosu na original **ikonički karakter više nije zadržan.**

Molimo okrenite sljedeću stranicu i pređite na sljedeći set fotografija na ekranu

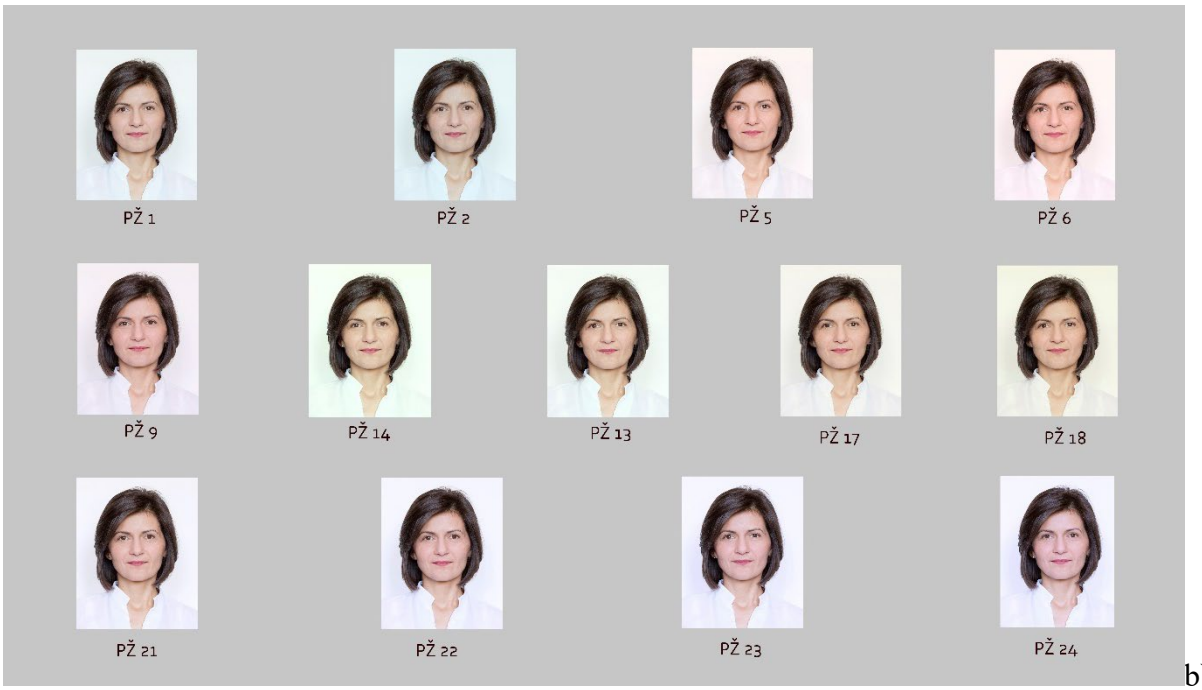
Slika 66 Prva stranica anketnog upitnika za eksperte

3.4. Treća faza-stupanj suglasnosti prigodnog uzorka ispitanika s izborom ekspertne skupine

Ovoj fazi istraživanja pristupili su ispitanici konzumenti koji imaju interes prema fotografiji.. Svi ispitanici prije pristupanja ispitivanju prolaze Ishihara test raspoznavanja boja[75]. (Slika 46) Za gledanje pripremljeni su setovi fotografija s motivima i pripadajućim šiframa bez fotografija za koje je skupina ispitanika eksperata zaključila da više ne zadržavaju stupanj ikoničnosti. Ispitanici u ovoj skupini fotografije promatraju memorijskim usklađivanjem gledanjem originala i seta s varijacijama, s tim da se ne mogu vratiti ponovno pogledati original. (Slika 67)



a)



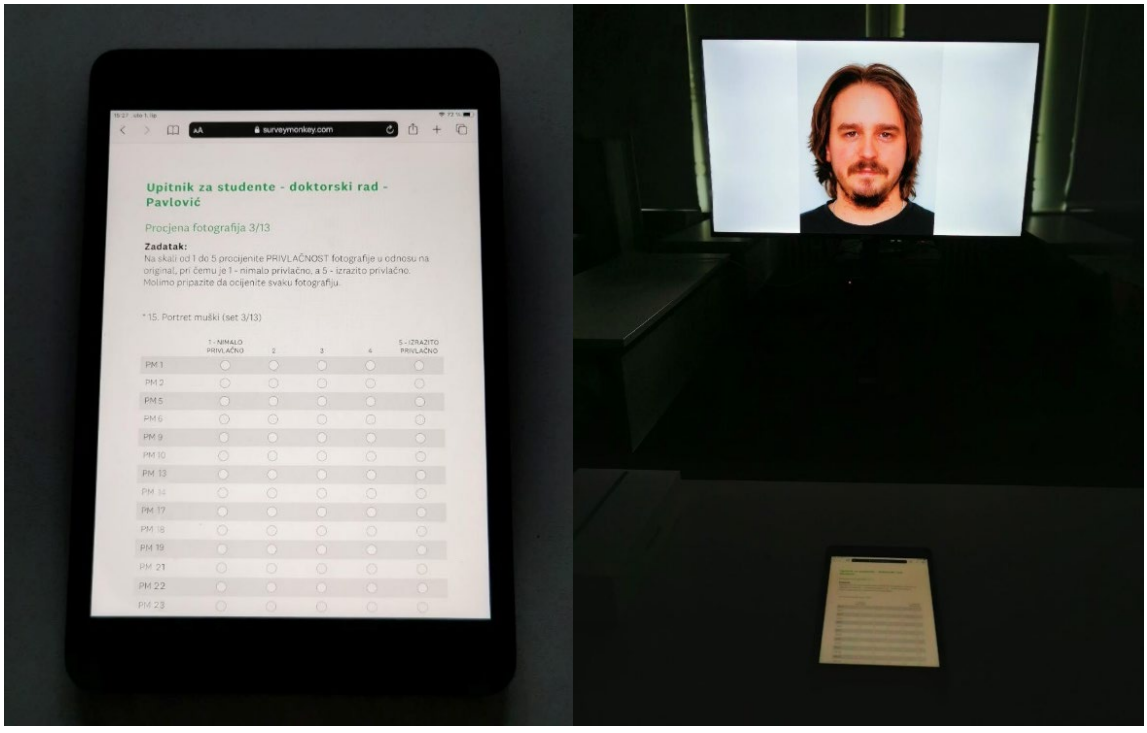
b)

Slika 67 Set fotografija pripremljen za gledanje ispitanicima konzumentima na primjeru seta fotografija ženskog portreta bez selekcije lica: a) original, b) set s fotografijama za koje su ispitanici eksperti zaključili da zadržavaju stupanj ikoničnosti

Fotografije su gledali na TCL 55"P615 4K Android TV [73][74] monitoru (Slika 68) kao i eksperti, ali su svoje ocjene za svaku viđenu fotografiju unosili na tablete u anketu formiranu online na platformi SurveyMonkey [76] (Slika 69). Nakon svakog seta fotografija bilo je obavezno napraviti pauzu.



Slika 68 Ispitanici konzumenti u trećoj fazi istraživanja pregledavaju fotografije



Slika 69 Survey monkey anketa -dio, primjer

3.5. Četvrta faza – zadržavanje ikoničnosti fotografskih slika u metamerijskim uvjetima konzumiranja

U ovoj fazi istraživanja sudjelovali su eksperti stručnjaci iz područja fotografije i vizualnih komunikacija na fotografijama odabranim u drugoj fazi istraživanja. Fotografije su za potrebe ove faze istraživanja isprintane na Epson SURECOLOR SC-P9500 SPECTRO printeru na 285 gramskom papiru Tecco Photo PL285 Luster [77][78]. Izrezane su na odgovarajuću veličinu (Slika 70) kako bi ih eksperti mogli složiti po redoslijedu u kućici za promatranje boja X Rite Judge II gdje su ih promatrali pod različitim izvorima svjetla.[79].



Slika 70 Dio uzoraka pripremljenih za ispitivanje u kućici za promatranje Judge II

Vizualnom percepcijom procjenjuje se mogućnost optimalnog zadržavanja ikoničnosti fotografske slike koja se konzumira u različitim svjetlosnim uvjetima. Ispitivanje se provodi memorijskim usklađivanjem testnih fotografskih slika odabranih u drugoj fazi istraživanja njihovom percepcijom uz različite standardne izvore svjetla (*Tablica 3*)– daylight (DAY D65 – 6500 K, tipična temperatura prosječnog sjevernog dnevnog svjetla), storelight (CWF/TL84 – 4100 K, temperatura korištena u Shopping centrima i prodajnim trgovinama) i homelight (CIE

A – 2856 K, tipično svjetlo za kućnu upotrebu) korištenjem komore za usuglašavanje boja, Gretag Macbeth Judge II. (Slika 71)

Tablica 3 Različiti izvora svjetla koji se nalaze u kućici za promatranje Gretag Macbeth Judge II

VRSTA SVJETLA	OZNAKA SVJETLA
volframova žarulja	A
dnevno sjeverno svjetlo, prosječno dnevno svjetlo	C -
- dnevno svjetlo, prosjek podnevnog svjetla diljem svijeta	D65
svjetlo na horizontu (izlazak i zalazak sunca)	D50
prosječno jutarnje i prosječno podnevno svjetlo	D55
- dnevno svjetlo prekrito oblacima	D75
- hladna bijela fluorescentna lampa	F2, FCW, CWF, F
fluorescentna lampa koja se koristi u trgovačkim centrima u Europi i USA	TL4 ili TL84
fluorescentna lampa koja se koristi u mnogim trgovačkim centrima u USA	Ultralume 3000

Ispitanici eksperti su memorijskim usklađivanjem prema redoslijedu sličnosti s originalom slagali uzorke za koje je u drugoj fazi procijenjeno da zadržavaju ikoničnost. (Slika 72)



a) b)

Slika 71 Eksperti promatraju uzorke pod različitim svjetlima u kućici za promatranje Judge II

Drugi zadatak eksperata bio je odabrati za svaki set fotografija onu fotografiju koja im je bila najprivlačnija za svako svjetlo. (Slika 72) Rezultati se temelje na ispitivanju skupine ispitanika-eksperata uz primjenu ordinalne ljestvice.

Istraživanje – doktorski rad – Pavlović Ivana

Obrazac za procjenu – eksperti - metamerija

ŠIFRA:
SPOL:
DOB:
RADNO MJESTO (područje rada):

1. Zadatak

Molimo da prikazane fotografije **rangirate** po sličnosti s originalnom fotografijom pri čemu je

1 mjesto – najsličnija originalu, a zadnje mjesto – najmanje slično originalu

Pored svakog ranga upišite šifru koju ste predvidjeli na to mjesto.

FOTOGRAFIJA: Portret ženski

	ŠIFRA FOTOGRAFIJE		
RANG	**1. SVJETLO (DAY LIGHT)**	**2. SVJETLO (STORE LIGHT)**	**3. SVJETLO (HOME LIGHT)**
1.			
2.			
3.			
4.			
5.			
6.			
7.			
8.			
9.			
10.			
11.			
12.			

Molimo upišite šifru fotografije koju procijenjujete:

	1. SVJETLO (DAY LIGHT)	**2. SVJETLO (STORE LIGHT)**	**3. SVJETLO (HOME LIGHT)**
NAJPRIVLAČNIJA			
NAJZDRAVIJA			
NAJMLAĐA			

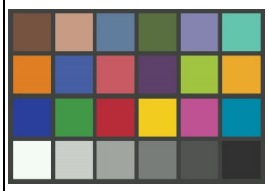
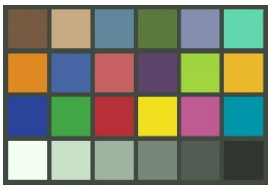
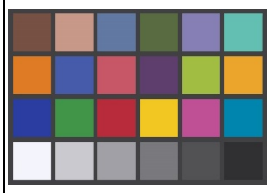
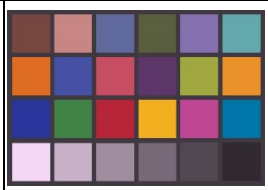
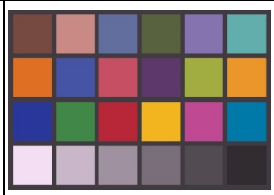
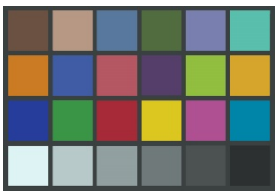
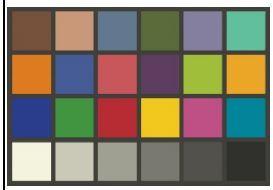
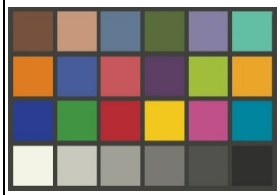
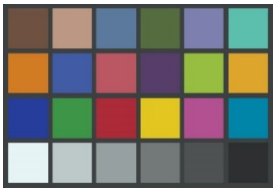
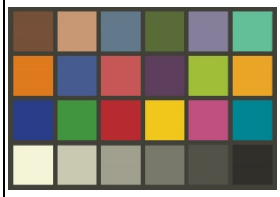
Molimo okrenite sljedeću stranicu i pređite na sljedeći set fotografija na ekranu

Slika 72 Primjer anketnog obrasca za eksperte za 4. dio istraživanja

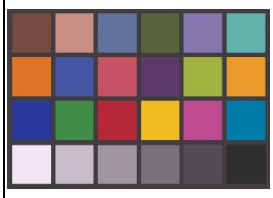
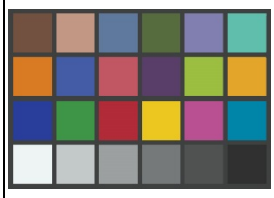
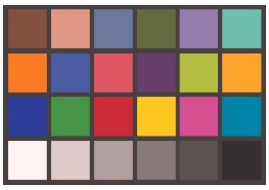
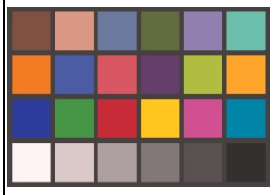
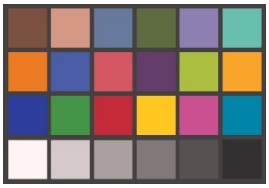
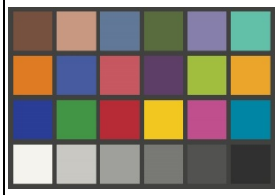
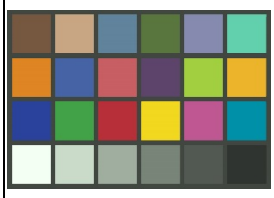
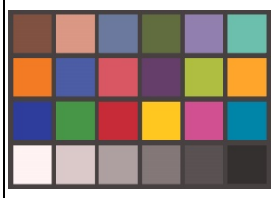
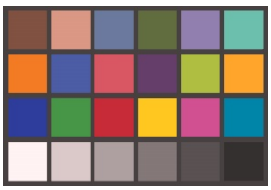
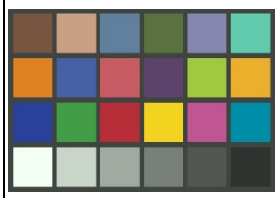
3.6. Peta faza- mjerno određivanje promjena boja

U ovoj se fazi istraživanja mjerno određuju promjene boja testnih fotografskih slika promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa fotografskih slika odabranih u drugoj fazi istraživanja. Temeljem mjerenja L, a i b vrijednosti pojedinih boja određuju se ukupne razlike boja za karakteristična polja ispitivanih fotografskih slika, za određene srednje Lab vrijednosti boja promatrane karakteristične selekcije fotografske slike i za prosječne Lab vrijednosti cijele površine promatrane fotografske slike. Također se određuje ukupna promjena boja tablica boja dobivenih promjenama plavog, zelenog i crvenog kanala zapisa standardne X-Rrite u odnosu na standardnu (polaznu) tablicu boja. Koraci promjene tablice boja su kao i kod setova fotografija 3% u granicama +/- 12% (Tablica 4 a i b). Ukupne razlike boja se određuju kao ΔE_{00} razlike boja, a kao granica prihvatljivosti je određena razlika ΔE_{00} manja od 6 jer se prema vrednovanju kolorimetrijske razlike boja sa stajališta standardnog promatrača razlika ΔE_{00} veća od 6 smatra jako velikom razlikom te nije prihvatljiva. [13][18] Uz određivanje ukupne razlike boja, određuju se i promjene u svjetlini (L*) i kromatičnosti (a* i b*) te se analiziraju histogrami fotografskih slika za ukupni zapis i pojedini kanal.

Tablica 4a) Tablica boja s promjenama vrijednosti crvenog, zelenog i plavog kanala (3 i 6 posto)

KANAL	Vrijednost promjene kanala			
	-3	+3	-6	+6
R				
G				
B				

Tablica 4b) Tablica boja s promjenama vrijednosti crvenog, zelenog i plavog kanala (9 i 12 posto) i original bez promjene

KANAL	Vrijednost promjene kanala			
	-9	+9	-12	+12
R				
G				
B				

3.7. Šesta faza

U šestoj se fazi istraživanja utvrđuje odnos između promjene percepcije i interpretacije promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa fotografskih slika primjenom odgovarajuće statističke metodologije.

S ciljem utvrđivanja tog odnosa eksperti su metodom simultanog binokularnog usuglašavanja unutar svakog fotografskog motiva izbacili one fotografije kod kojih je vrijednost promjene crvenog, zelenog i plavog kanala digitalnog zapisa dovela do gubitka navedenog zahtijeva. Pri tome je korištena ordinalna ljestvica procjene, a izbačene su one fotografije kod kojih je postojala 70% suglasnost ispitanika eksperata da ne ispunjavanju zahtjev zadržavanja ikoničnosti.

Fotografije za koje su eksperti zaključili da zadržavaju ikoničnost u usporedbi s originalom, ušle su u daljnje ispitivanje te su na njima prikupljene procjene ispitanika konzumenata o sličnosti s originalom i privlačnosti svake od fotografija Likertovom skalom, a koje su promatrali putem memorijskog usuglašavanja ne gledajući ponovno original. Na temelju tako prikupljenih rezultata proveden je izračun *Spearmanovih* koeficijenata korelacije između tipa

promijenjenih kanala digitalnog zapisa i vrijednosti njihove promjene, s procjenom privlačnosti fotografija.

Zatim su provedene 3*4 analize varijanci (ANOVA) kako bi se prikupile informacije o mogućem efektu interakcije vrijednosti promjene samog kanala zapisa i varijable kanala i njihov učinak na interpretaciju fotografskih slika od strane ispitanika konzumenata. Tom analizom provedena je i provjera interakcije samih varijabli odnosno da li privlačnost samih digitalnih zapisa fotografske slike ovisi o promjeni i vrsti kanala digitalnog zapisa fotografske slike. Analize varijanci provedene su za svaki motiv – portrete, pejzaže i fotografije hrane, i zasebno za fotografije s izmjenom na cijeloj površini fotografije i s izmjenom samo na selekciji digitalnog zapisa fotografske slike što je potkrijepljeno analizom za svaki od motiva.

Nakon ove faze fotografije odabrane u drugoj fazi išle na ispitivanje ispitanicima ekspertima koji su pod različitim izvorima svjetla gledali sve fotografije te memorijskim usklađivanjem dodijelili svakoj fotografiji rang prema kriteriju da fotografija najsličnija originalu dobiva rang broj jedan. Donesena je ukupna suma rangova te su u daljnjem koraku provedene analize varijanci neovisno o motivu za svaki izvor svjetla s kriterijem gledanja vrijednosti promjene kanala i glavnih efekata kanala te njihov interakcijski učinak uz uočavanje mogućih razlika pod različitim izvorima svjetla.

3.8. Opis uzorka ispitanika

U istraživanju je sudjelovalo više grupa ispitanika za različite faze ispitivanja. U drugoj fazi istraživanja sudjelovalo je 16 eksperata stručnjaka iz područja fotografije i vizualnih komunikacija (8 muškaraca i 8 žena) na temelju čijih procjena su utvrđene granice promjena kanala digitalnih zapisa unutar kojih se zadržava ikonički karakter fotografija. U trećoj fazi istraživanja sudjelovala su ukupno 104 ispitanika studenta Grafičkog fakulteta Sveučilišta u Zagrebu, od čega je 41,3% (*N*=43) njih bilo muškog, a 58,7% (*N*=61) ženskog spola. Prosječna dob sudionika iznosila je 22 godine (*M*=22,64, *SD*=5,78). Također, 74 (71,2%) studenta su u trenutku mjerenja pohađala diplomsku, a njih 30 (28,8%) preddiplomsku razinu studija. Isto tako, 66,3% (*N*=69) studenata bilo je upisano na smjer *Dizajn tehnoloških proizvoda*, a 33,7% (*N*=35) njih na *Tehničko-tehnološki smjer*. Prosječni interes sudionika za fotografiju iznosio je *M*=3,89 (*SD*=0,913). U četvrtoj fazi sudjelovalo je devet eksperata-stručnjaka na temelju čijih procjena je provjeravana uloga metamerije, od čega ih je šest bilo ženskog, a troje muškog spola. Svi ispitanici prošli su Ishihara test raspoznavanja boja.

4. REZULTATI I RASPRAVA

4.1. Odabir testnih fotografskih slika koje ispunjavaju uvjet zadržavanja ikoničkog karaktera

S ciljem utvrđivanja granica promjena crvenog, zelenog i plavog kanala digitalnog zapisa unutar kojih se još uvijek zadržava ikonički karakter fotografske slike ispitanici eksperti su metodom simultanog binokularnog usuglašavanja unutar svakog fotografskog motiva izbacili one fotografije kod kojih je vrijednost promjene crvenog, zelenog i plavog kanala digitalnog zapisa dovela do gubitka navedenog zahtijeva. Pri tome je korištena ordinalna ljestvica procjene, a izbačene su one fotografije kod kojih je postojala 70% suglasnost ispitanika eksperata da ne ispunjavanju zahtjev zadržavanja ikoničnosti. (Tablica 5)

Tablica 5 Šifre fotografija za koje su eksperti zaključili da više ne zadržavaju ikonički karakter

Ime i Šifra motiva	Šifra stupnjeva varijacije										
PŽ	3	4	7	8	10	11	12	15	16	19	20
PŽS	4	7	8	10	11	12	15	16	20	24	
PM	3	4	7	8	11	12	15	16	20		
PMS	4	7	8	10	11	12	16	20	24		
PD	3	4	7	8	11	12	15	16	20		
PDS	4	7	8	11	12	15	16	20			
LA	4	10	11	12	15	16	20				
LB	4	11	12	15	16	20					
LC	4	8	11	12	16						
HA	3	4	11	12	15	16	20				
HBS	4	8	11	12	16						
HC	3	4	8	10	11	12	15	16	20		
HCS	4	8	11	12	16						

Detaljna raspodjela izbačenih fotografskih uzoraka, po pojedinim motivima (s i bez selekcije), ovisno o kanalu digitalnog zapisa (crveni (R), zeleni (G) i plavi (B)), kao i o vrijednosti

promjene kanala prikazana je u tablicama (Tablica 6, Tablica 7, Tablica 8, Tablica 9, Tablica 10). Možemo primijetiti kako tropostotnim pojačavanjem ili oslabljivanjem bilo kojeg od kanala nije došlo do gubitka ikoničnosti fotografije te posljedično niti jedan od fotografskih uzoraka nije bio izbačen u niti jednom od korištenih motiva. Šestpostotno oslabljivanje kanala dovelo je do gubitka ikoničnosti u samo manjem broju slučajeva. Veći udio uzoraka fotografija je izbačen u slučaju devetpostotnog oslabljivanja, odnosno pojačavanja kanala unutar svakog od motiva. Najveći udio uzoraka fotografija zasigurno je izbačen u slučaju dvanaestpostotnog oslabljivanja/pojačavanja kanala digitalnog zapisa.

Tablica 6 Distribucija portreta koji nisu ispunili zahtjev zadržavanja ikoničkog karaktera s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa

	vrijednost promjene					ukupno
	-12	-9	-6	9	12	
R	3	3	0	3	3	12
G	3	3	1	3	3	13
B	3	1	0	0	0	4
ukupno	9	7	1	6	6	29

Tablica 7 Distribucija portreta (sa selekcijom lica) koji nisu zadržali ikonički karakter s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa

	vrijednost promjene					ukupno
	-12	-9	-6	9	12	
R	3	0	0	3	3	9
G	3	3	2	2	3	13
B	3	0	0	0	2	5
ukupno	9	3	2	5	8	27

Kod portreta u slučaju šestpostotnog oslabljivanja je izbačena samo jedna fotografija kod koje je mijenjan zeleni kanal zapisa, odnosno, dvije kod koje je mijenjan zeleni kanal, a kod kojih je promjena kanala bila ograničena samo na lice (selekcija).

U slučaju devetpostotnog oslabljivanja, odnosno pojačavanja kanala kod portreta možemo primijetiti da je veći udio (f=13) uzoraka izbačen kada je promjena digitalnog kanala bila

izvršena na čitavoj površini fotografije, u odnosu na onu koja je podrazumijevala ograničenu promjenu isključivo na licu (*f*=8). U prvom slučaju izbačene su po tri fotografije u kojima je pojačan odnosno oslabljen crveni i zeleni kanal, te jedna fotografija u kojoj je oslabljen plavi kanal. U drugom slučaju izbačena su tri uzorka kod kojih je oslabljen zeleni kanal, tri u kojima je pojačan crveni, te dvije u kojima je pojačan zeleni kanal digitalnog zapisa.

Kod portreta u slučaju dvanaestpostotnog oslabljivanja, odnosno pojačavanja kanala su izbačena sva tri uzorka u svakom od tri oslabljena kanala digitalnog zapisa, te sva tri uzorka u slučaju pojačavanja crvenog i zelenog kanala, dok niti jedan uzorak nije izbačen u slučaju pojačavanja plavog kanala. Slična situacija je bila i u slučaju portreta kod kojih je promjena kanala bila ograničena na lice. Jedino je u slučaju pojačavanja plavog kanala zadržana jedna fotografija, dok su svi drugi uzorci izbačeni.

Tablica 8 Distribucija pejzaža koji nisu zadržali ikonički karakter s obzirom na kanal i vrijednost promjene digitalnog zapisa

	vrijednost					
	-12	-9	-6	9	12	Ukupno
R	3	0	0	0	1	4
G	3	3	1	2	3	12
B	2	0	0	0	0	2
Ukupno	8	3	1	2	4	18

U slučaju šestpostotnog oslabljivanja kanala kod pejzaža izbačena je samo jedna fotografija kod koje je mijenjan zeleni kanal digitalnog zapisa, kao i kod portreta, ali i pejzaža.

Devetpostotno oslabljivanje, odnosno pojačavanje kanala kod pejzaža rezultiralo je izbacivanjem tri fotografije kod kojih je oslabljen zeleni kanal, odnosno, dvije kod kojih je isti kanal pojačan.

Kod dvanaestpostotnih promjena na fotografijama pejzaža su izbačena sva tri uzorka u slučaju oslabljivanja crvenog i zelenog kanala, te dva uzorka u slučaju oslabljivanja plavog kanala. Pri pojačavanju kanala, kod pejzaža je izbačen jedan uzorak kod pojačavanja crvenog kanala te sva tri uzorka u slučaju pojačavanja zelenog.

Tablica 9 Distribucija fotografija hrane koje nisu zadržale ikonički karakter s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa

	vrijednost					
	-12	-9	-6	9	12	Ukupno
R	2	2	0	0	1	5
G	2	2	1	2	2	9
B	2	0	0	0	0	2
Ukupno	6	4	1	2	3	16

Tablica 10 Distribucija fotografija hrane (sa selekcijom) koje nisu zadržale ikonički karakter s obzirom na kanal i vrijednost promjene digitalnog zapisa

	vrijednost			
	-12.0	-9.0	12.0	Ukupno
R	2	0	2	4
G	2	2	2	6
Ukupno	4	2	4	10

U slučaju šestpostotnog oslabljivanja kanala kod fotografija hrane, kao i kod fotografija portreta i pejzaža je također izbačena samo po jedna fotografija kod koje je također mijenjan zeleni kanal digitalnog zapisa.

Kod devetpostotnih promjena fotografija hrane izbačene su dvije fotografije u kojima je oslabljen crveni, tri u kojima je oslabljen zeleni te dvije u kojima je zeleni kanal digitalnog zapisa pojačan. U slučaju fotografije hrane kod koje je promjena kanala izvršena na ograničenom dijelu fotografije izbačen je uzorak u kojem je oslabljen zeleni kanal.

Kod dvanaestpostotnih promjena fotografija hrane izbačena su oba uzorka u slučaju oslabljivanja svakog od tri kanala digitalnog zapisa, dok su kod pojačavanja kanala izbačena oba uzorka pri pojačavanju zelenog, te jedan uzorak pri pojačavanju crvenog kanala. U slučaju fotografije hrane kod koje je promjena kanala bila ograničena na dio površine, izbačena su oba uzorka u kojima su pojačani, odnosno, oslabljeni crveni i zeleni kanal.

4.2. Utvrđivanje korelacije promjene percepcije i interpretacije promjenom vrijednosti kanala zapisa

4.2.1. Procjene prikupljene u trećoj fazi istraživanja - Likertova skala, Spearmanov koeficijent i dvosmjerna 3x4 ANOVA

S ciljem mogućnosti donošenja inferencijalnih zaključaka o efektima promjene vrijednosti kanala digitalnih zapisa, kako samog tipa kanala (R, G ili B), tako i vrijednosti promjene istih, te njihovog potencijalnog interakcijskog efekta na interpretaciju fotografija od strane konzumenata, istraživanjem su prikupljene i procjene konzumenata o privlačnosti svake varijacije na svakom od motiva korištenjem Likertove skale procjene od pet stupnjeva. U prvom koraku su izračunati *Spearmanovi* koeficijenti korelacije između tipa promijenjenih kanala digitalnog zapisa (neovisno o vrijednostima izmjene), kao i vrijednosti njihove promjene (neovisno o tipu), s procjenom privlačnosti fotografija. Prema tome se promjena plavog kanala digitalnog zapisa, neovisno o samim vrijednostima promjene, pokazala pozitivno povezanom s procjenom privlačnosti fotografije. Kao što možemo vidjeti u tablici (Tablica 11) jedino se promjena plavog kanala digitalnog zapisa, neovisno o samim vrijednostima promjene, pokazala pozitivno povezanom s procjenom privlačnosti fotografije. Drugim riječima, one fotografije kod kojih je promijenjen plavi kanal digitalnog zapisa, u odnosu na one kod kojih nije, rezultirale su većim procjenama privlačnosti konzumenata u slučaju tri motiva: portreta sa selekcijom lica (r= .255, p < .10), pejzaža (r=.305, p < .05), i motiva hrane s ograničenim područjem promjene kanala (r=.345, p < .05), dok jedino kod motiva portreta i hrane kod kojih je promjena izvršena na čitavoj površini fotografije povezanost nije bila statistički značajna. S druge strane, promjena zelenog kanala digitalnog zapisa, neovisno o vrijednostima promjene istog, se pak pokazala negativno povezanom s procjenom privlačnosti, odnosno, fotografije kod kojih je mijenjan zeleni kanal rezultirale su nižim procjenama privlačnosti u odnosu na one kod kojih taj kanal nije mijenjan i to samo na motivu hrane sa selekcijom (r=-.417, p < .01), dok na drugim motivima promjena zelenog kanala nije imala statistički značajan efekt na procjenu privlačnosti. Promjene crvenog kanala digitalnog zapisa nisu bile značajno povezane s privlačnosti fotografija na niti jednom motivu. Dobiveni statistički rezultati u pravilu potvrđuju rezultate ispitivanja provedenih kroz treću fazu ispitivanja, tj. određivanja stupnja suglasnosti prigodnog uzorka ispitanika s izborom ekspertne skupine.

Tablica 11 Povezanost kanala, kao i vrijednosti promjene kanala digitalnog zapisa i privlačnosti fotografije

	R	G	B	-12	-9	-6	-3	3	6	9	12
Portret	-0.36	-.157	.169	-	**-.338***	**-.498****	.187	**.631****	-.035	.004	-.213
Portret (selekcija)	-.198	-.076	**.255 (p < .10)**	-	**-.378***	-.068	**.325***	**.505****	-.18	**-.304***	-.139
Pejzaž	-.178	-.153	**.305***	-.031	**-.354****	-.060	**.395****	**.333***	-.033	-.189	-.203
Hrana	-.139	-.115	.229	-	-.252	-.219	**.386***	**.434***	-.065	-.215	-.285
Hrana (selekcija)	.028	**-.417****	**.345***	-.070	-.239	-.013	**.355***	**.313 (p < .10)**	-.036	**-.332***	-.073

Napomena. * $p < .05$, ** $p < .01$. Prikazani su Spearmanovi koeficijenti korelacije izračunati uz korištenje *dummy* varijanti varijabli kanala i vrijednosti promjene kanala

Kada je riječ o vrijednostima promjena kanala digitalnog zapisa, neovisno o tome o kojem kanalu se radi (R, G, ili B), možemo primijetiti kako je tropostotno pojačavanje vrijednosti kanala bilo pozitivno povezano s procjenama privlačnosti portreta s (r=.505, p < .01) i bez ograničavanja promjene na područje lica (r=.631, p < .01), pejzaža (r=.333, p < .05) kao i fotografija hrane bez (r=.434, p < .05) i sa selekcijom (r=.313, p < .10). Slično, tropostotno oslabljenje kanala digitalnog zapisa također je rezultiralo s većim procjenama privlačnosti portreta čija je promjena bila ograničena na područje lica (r=.325, p < .05), pejzaža (r=.395, p < .01) te fotografija hrane bez (r=.386, p < .05) i s ograničenim područjem promjene (r=.355, p < .05), dok značajna povezanost jedino nije utvrđena na motivu portreta dok značajna povezanost jedino nije utvrđena na motivu portreta bez selekcije. Sve druge promjene vrijednosti kanala digitalnog zapisa izvan granica +/- 3% ili nisu imale značajan efekt na procjenu privlačnosti fotografije, ili je pak efekt bio značajan, ali negativan, odnosno, veće vrijednosti promjene rezultirale su nižim procjenama privlačnosti. Tako je primjerice devetpostotno oslabljenje vrijednosti kanala bilo značajno negativno povezano s procjenama privlačnosti portreta (r=-.338, p < .05), portreta sa selekcijom lica (r=-.378, p < .05) i pejzaža (r=-.354, p < .01). Isto tako, šestpostotno oslabljenje kanala digitalnog zapisa bilo je negativno povezano s procjenom privlačnosti portreta (r=-.498, p < .10), dok je devetpostotno pojačavanje kanala bilo također negativno povezano s procjenom privlačnosti portreta kod kojeg je područje promjene bilo ograničeno na lice - portret sa selekcijom (r=-.304, p < .05, kao i s procjenom privlačnosti fotografija hrane sa selekcijom (r=-.332, p < .05).

Kako bismo dobili podrobnije informacije o potencijalnom efektu interakcije varijabli kanala i vrijednosti promjene kanala na interpretaciju fotografskih zapisa od strane konzumenata provedene su i dvosmjerne 3*4 analize varijanci (ANOVA), odvojeno po motivima. Navedena analiza osim samih glavnih efekata varijabli kanala (učinak vrste (R, G ili B) izmijenjenog kanala, neovisno o vrijednosti izmjene kanala) i vrijednosti promjene kanala (učinak same vrijednosti promjene kanala (-6, -3, +3, +6), neovisno o kojem se kanalu radi) omogućava i provjeru njihove interakcije, odnosno, ovisi li efekt jedne varijable o vrijednostima druge kada je u pitanju interpretacija fotografskog zapisa u vidu privlačnosti istog[80]. S obzirom na manji broj uzoraka fotografija s većim postotkom promjene kanala (9% i 12%) do kojeg je došlo uslijed neispunjavanja preduvjeta ikoničnosti, a koji onemogućuju procjenu aritmetičkih sredina privlačnosti fotografija kod pojedinih kombinacija varijabli kanala i vrijednosti promjene kanala, pri provedbi analize varijance uzeti su u obzir samo oni uzorci kod kojih su

promjene izvršene unutar +/- 6% kod svakog korištenog motiva kako bi rezultati bili međusobno usporedivi.

4.2.1.1. PORTRET BEZ SELEKCIJE

Na uzorku portreta bez selekcije utvrđena je statistička značajnost glavnih efekata varijabli kanala ($F(2,23)=29.212$; $p=.000$) i vrijednosti promjene kanala ($F(3,23)=54.449$; $p=.000$), kao i efekta interakcije varijabli kanala i vrijednosti promjene kanala ($F(6,23)=2.486$; $p=.053$). Drugim riječima, procjena privlačnosti fotografija ovisila je i o tome koji kanal digitalnog zapisa je promijenjen (neovisno o vrijednosti promjene kanala), kao i o vrijednosti promjene kanala (neovisno o tome koji kanal je promijenjen) te je efekt varijable kanala na privlačnost ovisio o vrijednostima promjene kanala (Tablica 12).

Tablica 12 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku portreta

	SS	*df*	*MS*	*F*	*p*
Model	7.47	11	.679	19.756	.000
Intercept	481.063	1	481.063	13993.839	.000
Kanal	2.008	2	1.004	29.212	.000
Vrijednost kanala	5.615	3	1.872	54.449	.000
Kanal * Vrijednost kanala	.513	6	.085	2.486	.053*
Pogreška	.791	23	.034		

Napomena. * efekt značajan na nešto liberalnijoj razini značajnosti od 10%

Kada je riječ o glavnom efektu kanala, pokazalo se da se portreti kod kojih je promijenjen plavi kanal smatraju privlačnijim od portreta kod kojih je promijenjen crveni i od portreta kod kojih je promijenjen zeleni kanal te da se portreti kod kojih je promijenjen crveni kanal smatraju privlačnijim od onih kod kojih je promijenjen zeleni kanal (Tablica 13, Tablica 14).

Tablica 13 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	4.043	.054	3.933	4.154
G	3.452	.057	3.335	3.570
R	3.697	.054	3.586	3.808

Tablica 14 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta s obzirom na kanal digitalnog zapisa

		Subsetovi		
	N	1	2	3
G	11	3.532343		
R	12		3.697115	
B	12			4.043269
p		1.000	1.000	1.000

Što se tiče glavnog efekta vrijednosti promjene kanala (Tablica 15, Tablica 16), utvrđeno je kako se portreti s tropostotno pojačanim kanalom smatraju privlačnijim od portreta s tropostotno oslabljenim i šestpostotno pojačanim kanalima digitalnog zapisa, kao i od portreta sa šestpostotno oslabljenim kanalima, dok statistički značajna razlika nije pronađena između portreta s tropostotno oslabljenim i šestpostotno pojačanim kanalima, odnosno, konzumenti su takve portrete smatrali jednako privlačnima. Međutim, isti su se procjenjivali privlačnijima od portreta sa šestpostotno oslabljenim kanalom digitalnog zapisa.

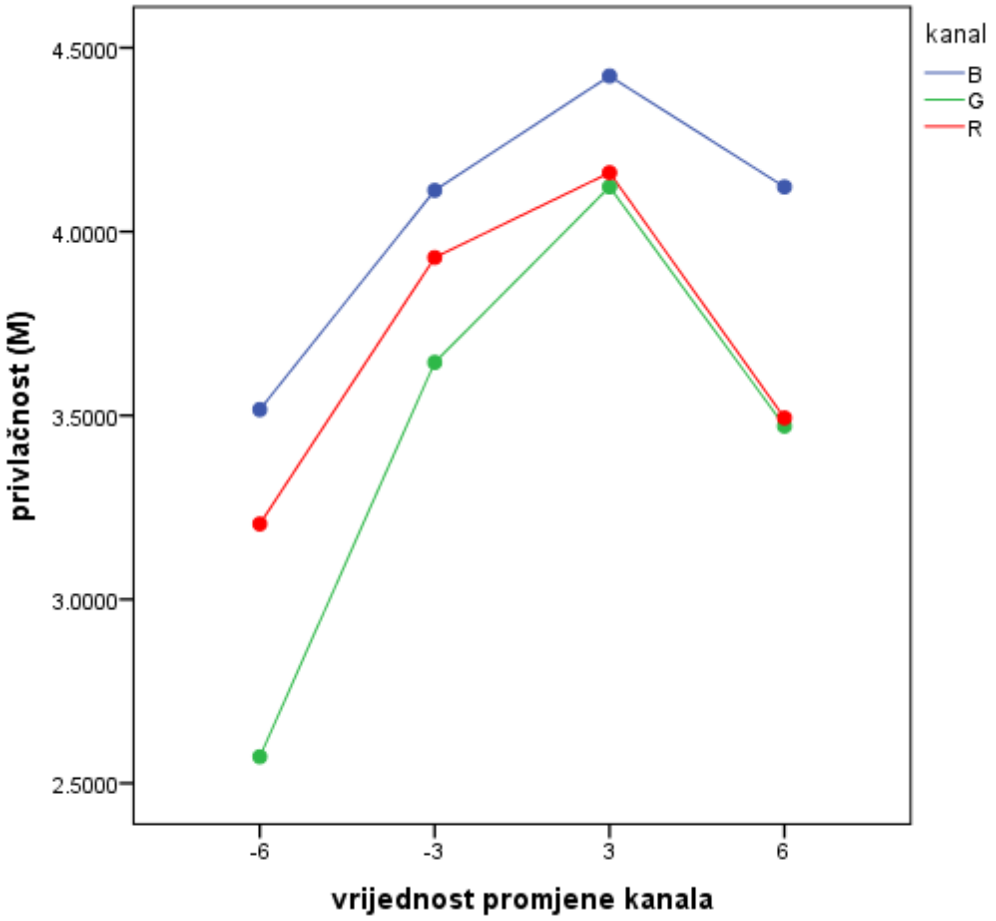
Tablica 15 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	3.098	.067	2.960	3.236
-3	3.895	.062	3.767	4.023
3	4.235	.062	4.107	4.363
6	3.696	.062	3.568	3.823

Tablica 16 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta s obzirom na vrijednost promjene kanala digitalnog zapisa

		Subsetovi		
	N	1	2	3
-6	8	3.163462		
6	9		3.695513	
-3	9		3.895299	
3	9			4.235043
p		1.000	.063	1.000

Na slici možemo uočiti ovisnost glavnog efekta varijable kanala o vrijednostima kanala (Slika 73). Iako se, neovisno o vrijednostima promjene kanala, portreti kojima je promijenjen crveni kanal smatraju privlačnijim od portreta kojima je promijenjen zeleni kanal, navedena prednost se gubi ako se radi o tropostotnom i šestpostotnom pojačanju kanala budući da su procjene privlačnosti na tim razinama promjene gotovo identične, dok je na razini šestpostotnog oslabljenja kanala navedena prednost najviše izražena.



Slika 73 Prosječna privlačnost portreta ovisno o kanalu i vrijednost promjene kanala digitalnog zapisa

4.2.1.2. PORTRET SA SELEKCIJOM

Kao i kod portreta kod kojih promjene kanala digitalnog zapisa nisu bile izolirane na manji dio površine fotografije, kod portreta kod kojih su promjene bile ograničene isključivo na lice, također je utvrđena statistička značajnost glavnih efekata varijabli kanala ($F(2,23)=9.990$; $p=.001$) i vrijednosti promjene kanala ($F(3,23)=11.447$; $p=.000$), kao i efekta interakcije varijabli kanala i vrijednosti promjene kanala ($F(6,23)=2.229$; $p=.071$) (Tablica 17).

Tablica 17 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku portreta sa selekcijom

	SS	*df*	*MS*	*F*	*p*
Model	6.242	11	.567	5.453	.000
Intercept	437.645	1	437.645	4205.127	.000
Kanal	2.079	2	1.040	9.990	.001
Vrijednost kanala	3.574	3	1.191	11.447	.000
Kanal * Vrijednost kanala	1.436	6	.239	2.299	.071*
Pogreška	2.290	22	.104		

Napomena. * efekt značajan na nešto liberalnijoj razini značajnosti od 10%

Kao i ranije, portreti kod kojih je promijenjen plavi kanal digitalnog zapisa procijenjeni su privlačnijima i od portreta kod kojih je promijenjen crveni i od portreta kod kojih je promijenjen zeleni kanal, međutim, portreti s izmjenama crvenog i zelenog kanala nisu se statistički značajno razlikovali na procjenama privlačnosti (Tablica 18, Tablica 19).

Tablica 18 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta sa selekcijom ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	4.116	.093	3.923	4.309
G	3.504	.114	3.267	3.741
R	3.678	.093	3.485	3.871

Tablica 19 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta sa selekcijom s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	10	3.650962	
R	12	3.677885	
B	12		4.116186
p		0.854	1.000

Nadalje, portreti s tropostotno pojačanim, kao i tropostotno oslabljenim kanalima smatrani su privlačnijim od portreta sa šestpostotno pojačanim, odnosno, šestpostotnim oslabljenim

kanalima, dok razlika u privlačnosti nije utvrđena između portreta s tropostotnim pojačanjem i tropostotnim oslabljenjem, kao ni između portreta sa šestpostotnim pojačanjem i šestpostotnim oslabljenjem kanala digitalnog zapisa (Tablica 20, Tablica 21).

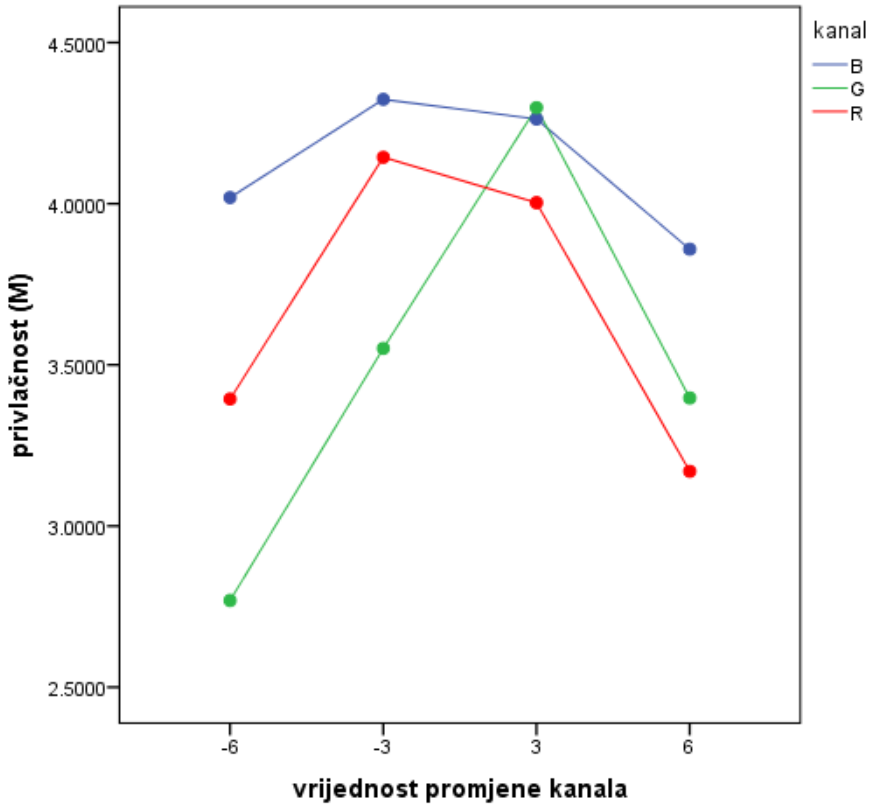
Tablica 20 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta sa selekcijom ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	3.394	.139	3.106	3.682
-3	4.006	.108	3.783	4.229
3	4.188	.108	3.965	4.411
6	3.475	.108	3.252	3.698

Tablica 21 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta sa selekcijom s obzirom na vrijednost promjene kanala digitalnog zapisa

		Subsetovi	
	N	1	2
6	9	3.475427	
-6	7	3.572802	
-3	9		4.006410
3	9		4.188034
p		0.822	.430

Također, kod portreta sa selekcijom utvrđen je i drugačiji efekt interakcije varijabli kanala i vrijednosti promjene kanala (Slika 74). Iako su promjene plavog i crvenog kanala rezultirale s višim procjenama privlačnosti u odnosu na zeleni u slučaju šestpostotnog i tropostotnog oslabljenja kanala, na razini tropostotnog pojačanja, promjena zelenog kanala rezultirala je gotovo identičnom procjenom privlačnost kao i promjena plavog kanala te ujedno i višom procjenom privlačnosti u odnosu na crveni kanal digitalnog zapisa. U slučaju šestpostotnog pojačanja, fotografije s promjenom zelenog kanala ipak bile procijenjene manje privlačnima od onih kod kojih je promijenjen plavi kanal, ali je procjena privlačnosti i dalje bila viša u odnosu na fotografije kojima je izmijenjen crveni kanal digitalnog zapisa.



Slika 74 Prosječna privlačnost portreta sa selekcijom s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa

4.2.1.3. PEJZAŽ

Kao i u ranijim analizama portreta bez i sa selekcijom površine, kod pejzaža (Tablica 22) je također utvrđena statistička značajnost glavnih efekata varijabli kanala ($F(2,23)=7.383$; $p=.003$) i vrijednosti promjene kanala ($F(3,23)=5.366$; $p=.006$) na procjenu privlačnosti. Međutim, efekt interakcije nije se pokazao statistički značajnim ($F(6,23)=0.387$; $p=.880$).

Tablica 22 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku pejzaža

	SS	*df*	*MS*	*F*	*p*
Model	2.524	11	.229	2.875	.016
Intercept	518.404	1	518.404	6495.147	.000
Kanal	1.179	2	0.589	7.383	.003
Vrijednost kanala	1.285	3	0.428	5.366	.006
Kanal * Vrijednost kanala	.185	6	.031	0.387	.880
Pogreška	1.836	23	.080		

Pejzaži kod kojih je promijenjen plavi kanal digitalnog zapisa procijenjeni su privlačnijim od pejzaža kod kojih je promijenjen zeleni kanal te jednako privlačnim u odnosu na pejzaže kod kojih je promijenjen crveni kanal. Isto tako, razlika u privlačnosti između pejzaža kod kojih je

promijenjen crveni kanal i onih kod kojih je promijenjen zeleni kanal također nije bila statistički značajna (Tablica 23, Tablica 24).

Tablica 23 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti pejzaža ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	4.091	.082	3.922	4.259
G	3.634	.087	3.455	3.813
R	3.894	.082	3.726	4.063

Tablica 24 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti pejzaža s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	11	3.659091	
R	12	3.894231	3.894231
B	12		4.090545
p		0.063	0.102

Nadalje, pejzaži s tropostotnim oslabljenjem kanala procijenjeni su privlačnijim od pejzaža sa šestpostotnim oslabljenjem, kao i šestpostotnim pojačanjem kanala digitalnog zapisa. Pejzaži s tropostotnim pojačanjem kanala nisu se razlikovali u privlačnosti od kanala s tropostotnim oslabljenjem, kao ni od pejzaža sa šestpostotnim pojačanjem, odnosno, oslabljenjem digitalnog zapisa (Tablica 25, Tablica 26).

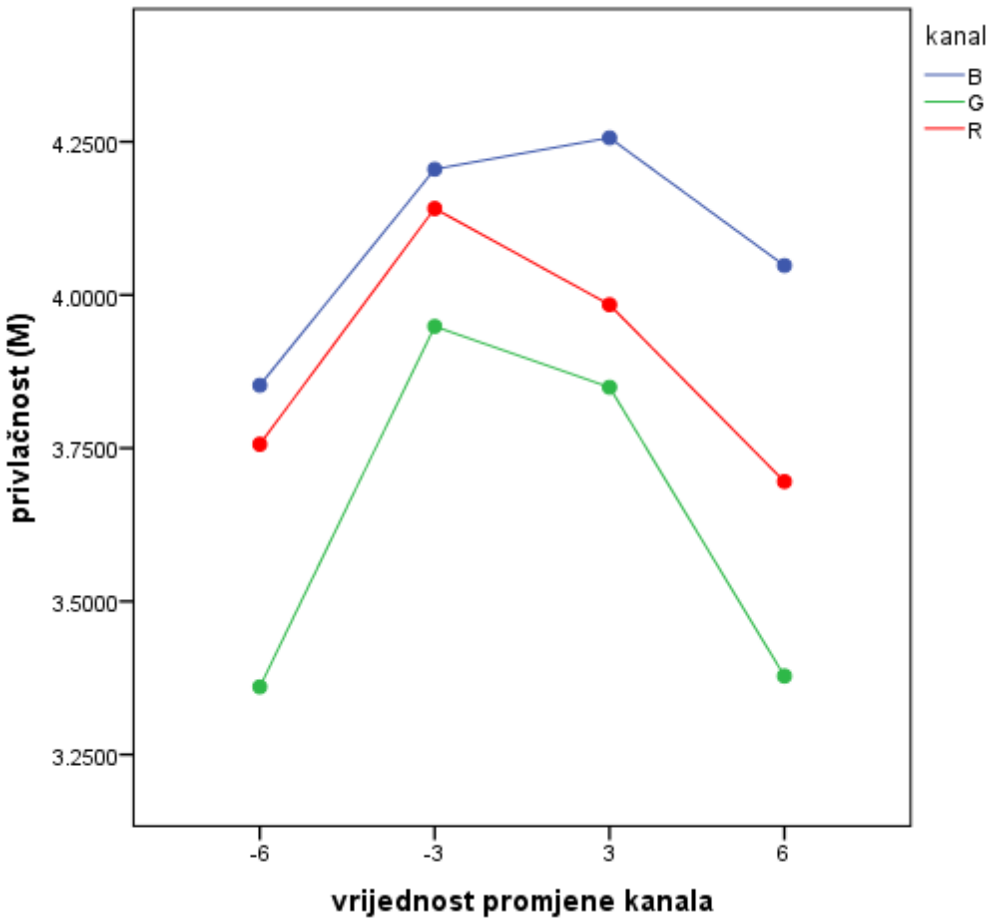
Tablica 25 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti pejzaža ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	3.657	.102	3.446	3.867
-3	4.098	.094	3.903	4.293
3	4.030	.094	3.835	4.225
6	3.707	.094	3.512	3.902

Tablica 26 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti pejzaža s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi	
	N	1	2
-6	8	3.693510	
6	9	3.707265	
3	9	4.029915	4.029915
-3	9		4.098291
p		0.059	.850

Za razliku od portreta, kao i portreta kod kojih je promjena kanala digitalnog zapisa bila ograničena na lice, kod pejzaža nije utvrđena ovisnost efekta varijable kanala o razinama varijable promjene vrijednosti kanala, odnosno, efekt varijable kanala na privlačnost bio je podjednak na svim razinama varijable vrijednosti promjene kanala i obrnuto (Slika 75).



Slika 75 Prosječna privlačnost pejzaža s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa

4.2.1.4. HRANA BEZ SELEKCIJE

Kod fotografija hrane, također je utvrđena značajnost glavnih efekata varijabli kanala ($F(2,11)=11.848$; $p=.002$) i vrijednosti promjene kanala ($F(3,11)=11.031$; $p=.001$), kao i efekta interakcije varijabli kanala i vrijednosti promjene kanala ($F(6,11)=4.506$; $p=.015$) (Tablica 27).

Tablica 27 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku fotografija hrane

	SS	*df*	*MS*	*F*	*p*
Model	6,167	11	,561	8,054	,001
Intercept	301,633	1	301,633	4333,146	,000
Kanal	1,650	2	0,825	11,848	,002
Vrijednost kanala	2,304	3	0,768	11,031	,001
Kanal * Vrijednost kanala	1,882	6	,314	4,506	,015
Pogreška	,766	11	,070		

Fotografije hrane kod kojih je promijenjen plavi kanal digitalnog zapisa procijenjene su privlačnijima od onih kojima je promijenjen crveni, kao i onih kojima je promijenjen zeleni kanal, dok su fotografije s promjenom crvenog i zelenog kanala smatrane jednako privlačnima (Tablica 28, Tablica 29).

Tablica 28 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	4,053	,093	3,848	4,258
G	3,391	,104	3,161	3,620
R	3,626	,093	3,421	3,832

Tablica 29 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	7	3,409341	
R	8	3,626202	
B	8		4,052885
p		0,152	1,000

Isto tako, fotografije hrane s tropostotno oslabljenim kanalom digitalnog zapisa, kao i tropostotno pojačanim kanalom, smatrane su privlačnijim od fotografija hrane sa šestpostotno

oslabljenim, odnosno, šestpostotno pojačanim kanalom digitalnog zapisa, dok između fotografija s tropostotno ojačanim i tropostotno oslabljenim kanalom, kao i između onih sa šestpostotno oslabljenim i šestpostotno ojačanim kanalom digitalnog zapisa, nije utvrđena razlika u privlačnosti. (Tablica 30, Tablica 31).

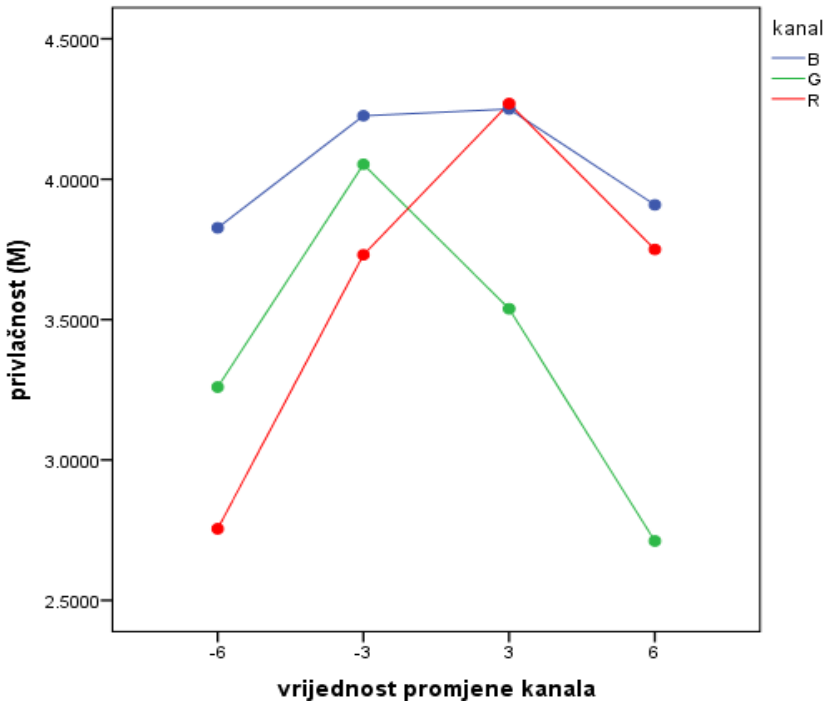
Tablica 30 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	3,280	,124	3,007	3,554
-3	4,003	,108	3,766	4,240
3	4,019	,108	3,782	4,256
6	3,457	,108	3,220	3,694

Tablica 31 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi	
	N	1	2
-6	5	3,284615	
6	6	3,456731	
-3	6		4,003205
3	6		4,019231
p		0,544	,993

Na slici koja prikazuje prosječnu privlačnost fotografija hrane ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa (Slika 76) možemo uočiti kako efekt varijable kanala digitalnog zapisa na procjenu privlačnosti fotografija hrane nije bio podjednak na svim razinama varijable vrijednosti promjene kanala digitalnog zapisa. Kod fotografija sa šestpostotnim, kao i tropostotnim oslabljivanjem kanala vidimo da su fotografije kod kojih je mijenjan plavi kanal procjene privlačnijim od onih kod kojih je mijenjan zeleni, a koje su pak procijenjene privlačnijima od onih kojima je mijenjan crveni kanal digitalnog zapisa. Međutim, u slučaju tropostotnog pojačanja kanala, izmjene crvenog kanala dovele su u prosjeku do nešto većih procjena privlačnosti u odnosu na izmjene plavog kanala, dok su u slučaju šestpostotnog pojačanja kanala procjene privlačnosti fotografija hrane s izmjenama plavog i crvenog kanala bile podjednake.



Slika 76 Prosječna privlačnost fotografija hrane ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa

4.2.1.5. HRANA SA SELEKCIJOM

Kod fotografija hrane s ograničenim područjem izmjene (selekcija) utvrđena je jedino statistička značajnost glavnog efekta varijable kanala digitalnog zapisa ($F(2,12)=6.552$; $p=.012$), dok glavni efekt varijable vrijednost promjene kanala ($F(3,12)=2.342$; $p=.125$), kao i efekta interakcije varijabli kanala i vrijednosti promjene kanala ($F(6,12)=0.272$; $p=.940$) nisu utvrđeni (Tablica 32).

Tablica 32 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku fotografija hrane sa selekcijom

	SS	*df*	*MS*	*F*	*p*
Model	1,424	11	,129	1,978	,128
Intercept	379,093	1	379,093	5792,701	,000
Kanal	0,858	2	0,429	6,552	,012
Vrijednost kanala	0,460	3	0,153	2,342	,125
Kanal * Vrijednost kanala	,107	6	,018	0,272	,940
Pogreška	,785	12	,065		

Fotografije hrane sa selekcijom kod kojih je promijenjen plavi, kao i crveni kanal digitalnog zapisa procjene su privlačnijima od onih kojima je promijenjen zeleni kanal, dok su fotografije s promjenom plavog i crvenog kanala smatrane jednako privlačnima (Tablica 33, Tablica 34).

Tablica 33 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	4,167	,090	3,970	4,364
G	3,718	,090	3,520	3,915
R	4,038	,090	3,841	4,236

Tablica 34 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	8	3,717548	
R	8		4,038462
B	8		4,167067
p		1,000	0,335

S druge strane, procjene privlačnosti fotografija hrane sa selekcijom bile su približno podjednake na svim razinama varijable vrijednosti promjene kanala digitalnog zapisa (Tablica 35, Tablica 36).

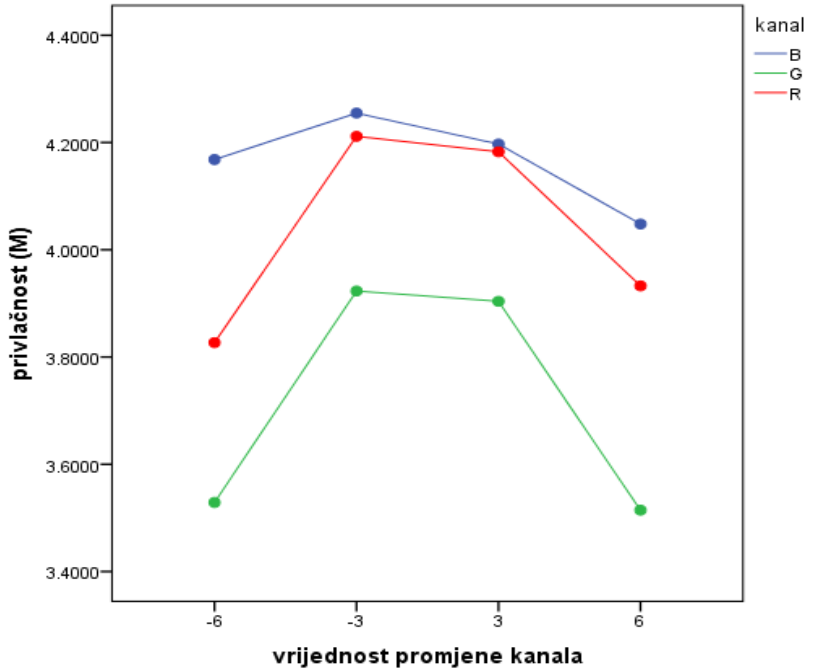
Tablica 35 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	3,841	,104	3,614	4,069
-3	4,130	,104	3,902	4,357
3	4,095	,104	3,867	4,322
6	3,832	,104	3,604	4,059

Tablica 36 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi
	N	1
6	6	3,831731
-6	6	3,841346
3	6	4,094551
-3	6	4,129808
p		0,235

Za razliku od fotografija hrane kod kojih je promjena kanala izvršena na čitavoj površini fotografije, u slučaju fotografija hrane s ograničenim područjem promijene (selekcija) nije utvrđena ovisnost efekta varijable kanala o razinama varijable promjene vrijednosti kanala, odnosno, efekt varijable kanala na privlačnost bio je podjednak na svim razinama varijable vrijednosti promjene kanala i obrnuto (Slika 77).



Slika 77 Prosječna privlačnost fotografija hrane sa selekcijom ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa

4.2.2. Procjene prikupljene u trećoj fazi istraživanja - subjektivna procjena - odabir fotografskih slika temeljem traženih atributivnih karakteristika

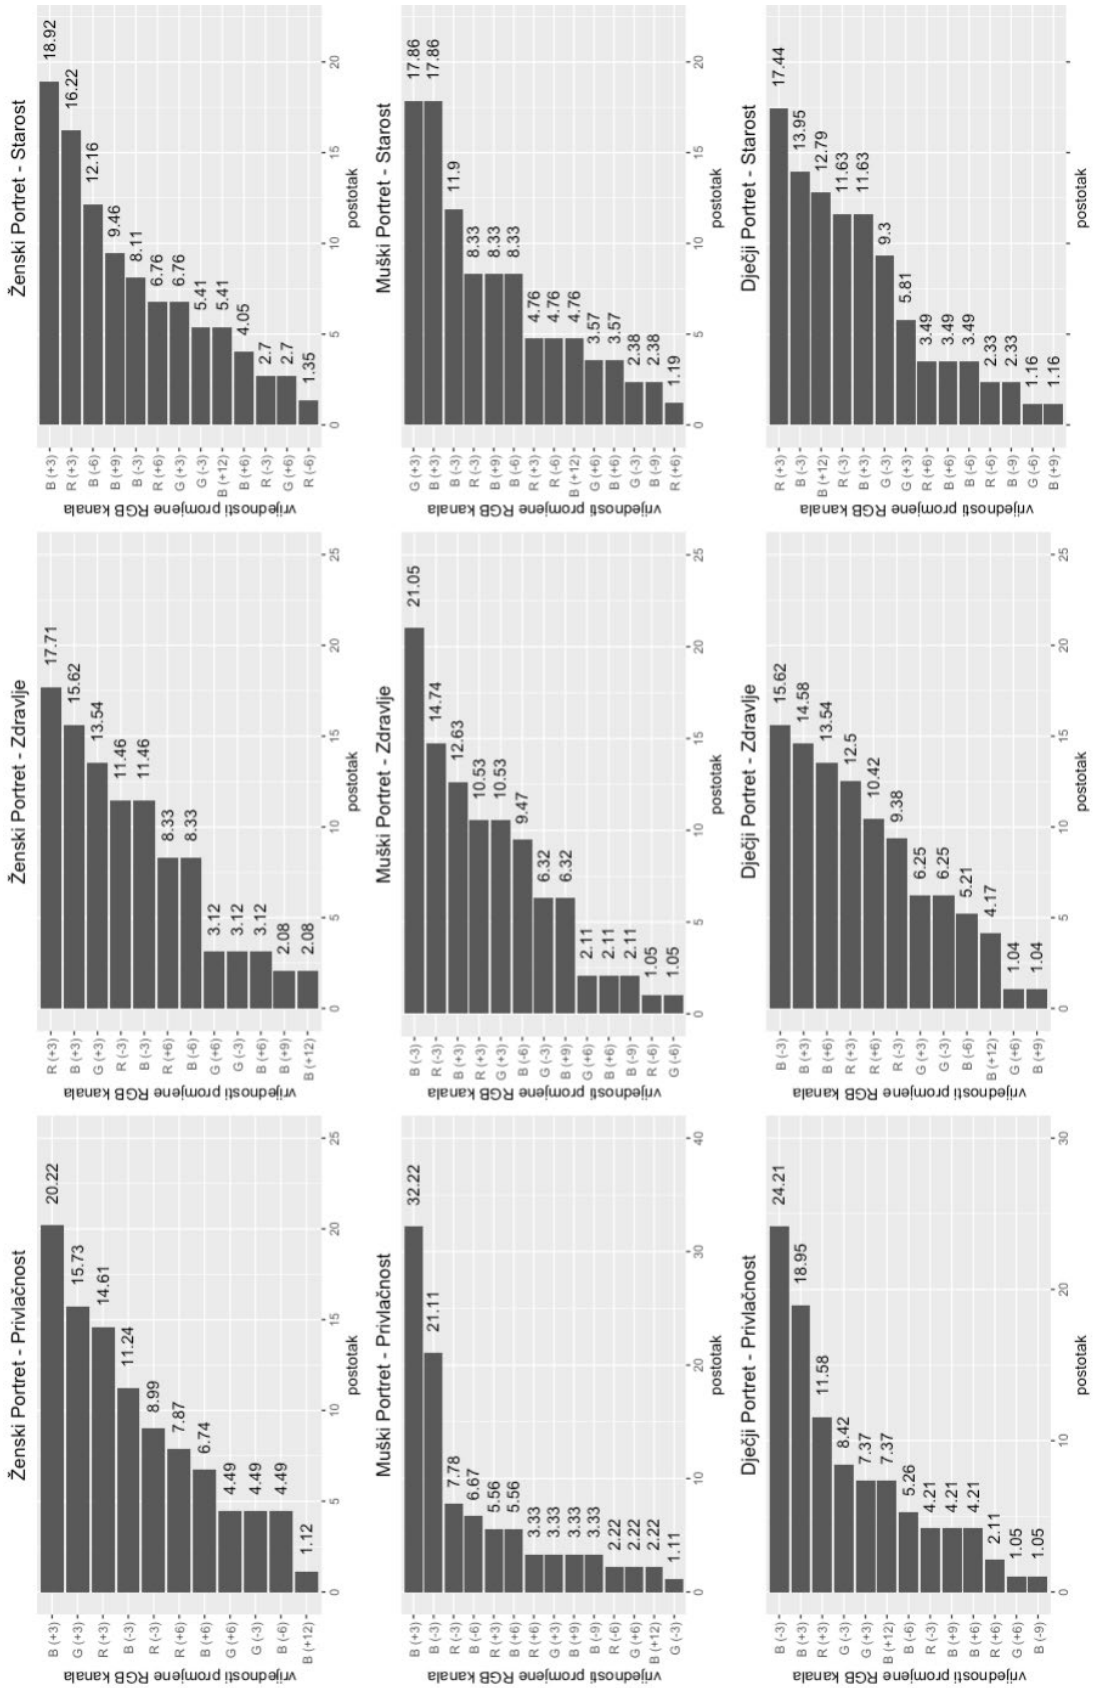
Budući da se promjenama vrijednosti kanala digitalnog zapisa potencijalno može oblikovati percepcija i utjecati na interpretaciju fotografskih zapisa istraživanjem su, unutar svakog od tri motiva i za svaku od tri korištene fotografije po motivu, prikupljene procjene ispitanika konzumenata (n=100; 4 sudionika nisu uključena u uzorak zbog nedostatnih podataka) o optimalnim varijacijama originalnih fotografija (Slika 78**,** Slika 79**,** Slika 80**,** Slika 81**,** Slika 82) pri čemu nisu procjenjivali one fotografije koje su eksperti procijenili da ne zadržavaju ikonički karakter. Tako su kod portreta trebali odabrati jednu od varijacija na kojoj osoba izgleda najprivlačnije, jednu na kojoj izgleda najzdravije te jednu na kojoj izgleda najmlađe i to za svaku od tri originalne fotografije (žena, muškarac, dijete).

Kod fotografija portreta s varijacijama napravljenim na cijeloj površini slike (Slika 80) kao što možemo vidjeti, konzumenti su daleko najčešće odabirali varijacije s tropostotnim pojačanjem,

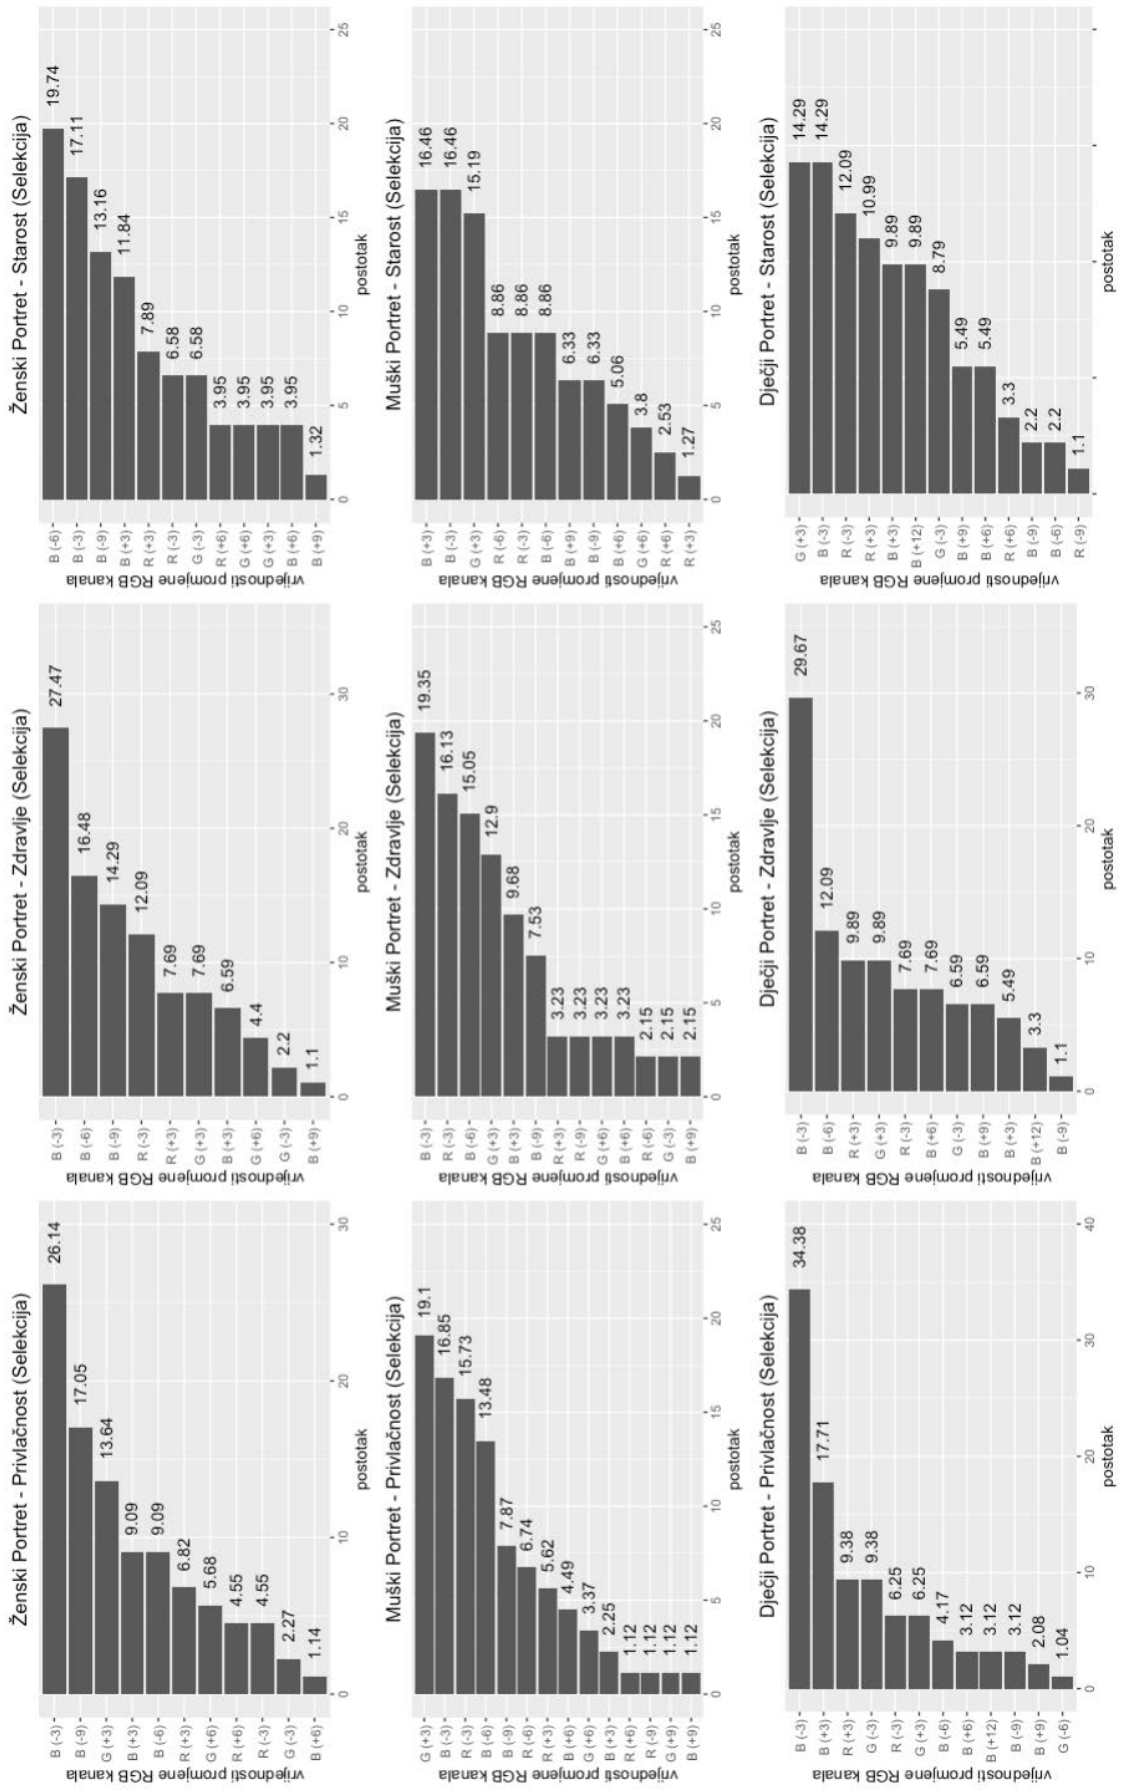
odnosno, oslabljenjem pojedinog kanala digitalnog zapisa. Tako su, kada je riječ o privlačnosti portreta, najprivlačnijim varijacijama ženskih portreta u najvećem broju slučajeva odabirali one s tropostotnim pojačanjima plavog (20.22%), zelenog (15.73%) i crvenog (14.61%) kanala digitalnog zapisa. Kod muških portreta najveći broj njih je najprivlačnijim smatrao portret s tropostotno pojačanim (32.22%), odnosno, oslabljenim (21.11%) plavim kanalom, a sličan obrazac nalaza utvrđen je i kod dječjih portreta – 24.21% njih odabralo je varijaciju s tropostotno oslabljenim, odnosno, 18.95% s tropostotno pojačanim plavim kanalom digitalnog zapisa. Najzdravijim ženskim portretima najčešće su smatrani oni s tropostotnim pojačanjem crvenog (17.71%), plavog (15.62%) i zelenog (13.54%) kanala, dok su muških portreti s tropostotnim oslabljenjem plavog (21.05%) i crvenog (14.74%) te tropostotnim pojačanje plavog (12.63%) kanala najčešće smatrani najzdravijim. Najzdravijim dječjim portretima najčešće su smatrani oni s tropostotnim oslabljivanjem (15.62%), odnosno, pojačavanjem (14.58%) plavog kanala, kao i šestpostotnim pojačavanjem plavog (13.54%) te tropostotnim pojačavanjem crvenog (12.5%) kanala. Najmlađim ženskim portretom najčešće su smatrani oni čiji su plavi (18.92%) i crveni (16.22%) kanali digitalnog zapisa pojačani za tri posto (12.16%). S druge strane, kao najmlađi muški portreti najčešće su odabirani oni s tropostotnim pojačanjem zelenog (17.86%) i plavog kanala (17.86%). Kod dječjeg portreta, najmlađom varijacijom smatrana je ona s tropostotnim pojačavanjem crvenog kanala digitalnog zapisa (17.44%).

Kada je riječ o portretima u kojima su promjene vrijednosti digitalnog kanala bile ograničene na područje lica (Slika 81), najprivlačnijom varijacijom ženskog (26.14%), kao i dječjeg (34.38%) portreta najčešće je birana ona u kojoj plavi kanal oslabljen za tri posto, dok su kod muških portreta tropostotno pojačanje zelenog (19.1%), kao i tropostotno oslabljenje plavog (16.85%) i crvenog (15.73%) kanala najčešće smatrani najprivlačnijim varijacijama. Kada je riječ o procjeni zdravlja portreta sa selekcijom, kod ženskih (27.47%) i dječjih (29.67%) portreta dobiven je isti obrazac nalaza kao i kod procjene privlačnosti – tropostotno oslabljenje plavog kanala najčešće je birano kao najzdravija varijacija navedenih portreta. Kod muških portreta, najzdravijom varijacijama najčešće su birane one s tropostotnim slabljenjem plavog (19.35%) i crvenog (16.13%), odnosno šestpostotnim slabljenjem plavog kanala (15.05%). Najmlađim ženskim portretima sa selekcijom najčešće su birane varijacije sa šestpostotnim (19.74%) i tropostotnim (17.11%) oslabljenjem plavog kanala, dok su najmlađim varijacijama muških portreta najčešće proglašene one s tropostotnim pojačanjem (16.46%), odnosno, oslabljenjem (16.46%) plavog kanala te tropostotnim pojačanjem zelenog kanala digitalnog zapisa (15.19%). Kod dječjih portreta sa selekcijom, varijacije s tropostotnim pojačanjem

zelenog (14.29%), tropostotnim oslabljenjem plavog (14.29%), kao i tropostotnim oslabljenjem crvenog kanala (12.09%) najčešće su birane kao najmlađe..



Slika 78 Učestalost odabira uzoraka portreta bez selekcije na atributima privlačnosti, zdravlja i starosti



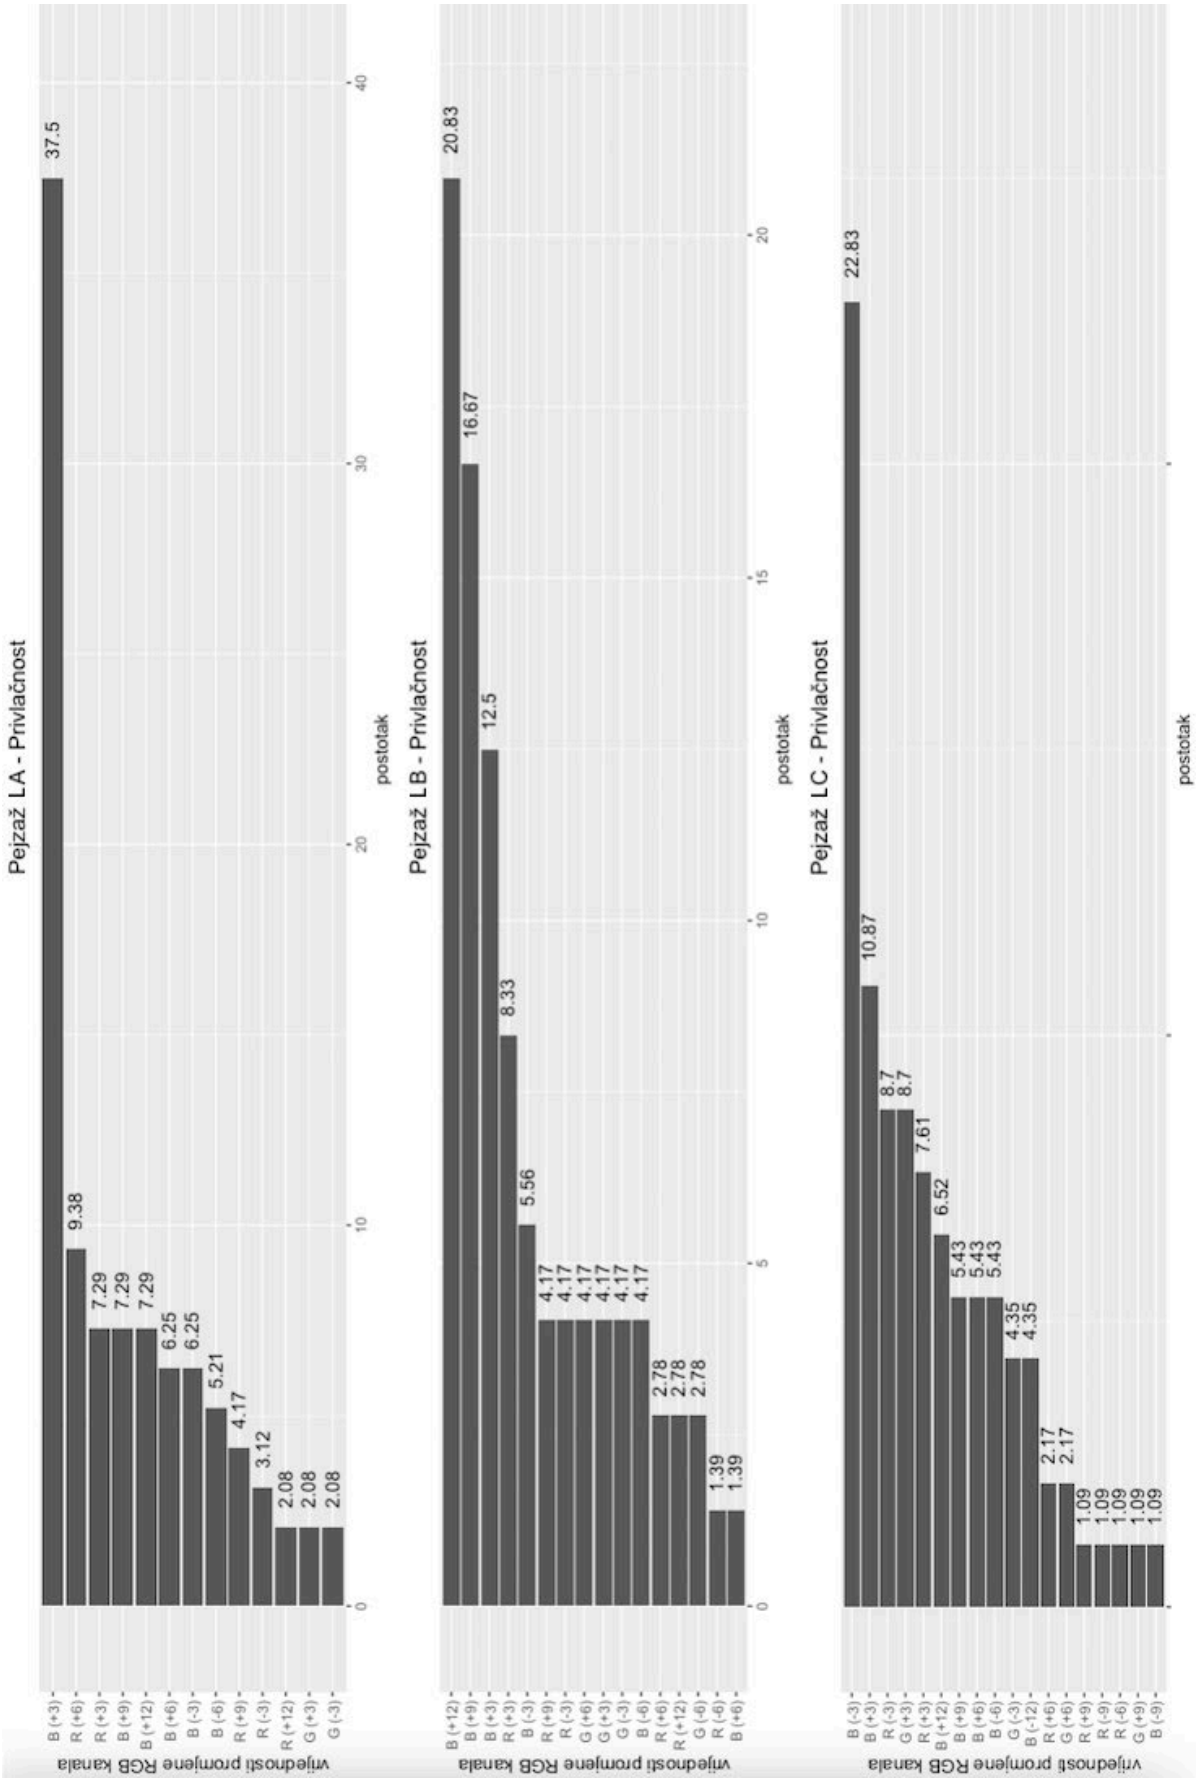
Slika 79 Učestalost odabira uzoraka portreta sa selekcijom lica na atributima privlačnosti, zdravlja i starosti

Kod pejzažnog motiva (Slika 80), sudionici konzumenti su trebali odabrati jednu od varijanti promjene kanala digitalnih zapisa kao optimalnu po pitanju privlačnosti. Kod prvog pejzažnog fotografskog prikaza (LA) u najvećem broju slučajeva je kao najprivlačnija odabrana varijanta s tropostotnim pojačanjem plavog kanala (37.5%), dok su kod drugog pejzažnog prikaza (LB) najprivlačnijim varijantama smatrane one s dvanaestpostotnim (20.83%) te devetpostotnim (16.67%) pojačanjem plavog kanala. Kod posljednjeg pejzažnog prikaza (LC), najprivlačnijom varijantom je u najvećem broju slučajeva (22.83%) odabrana ona s tropostotnim oslabljenjem plavog kanala.

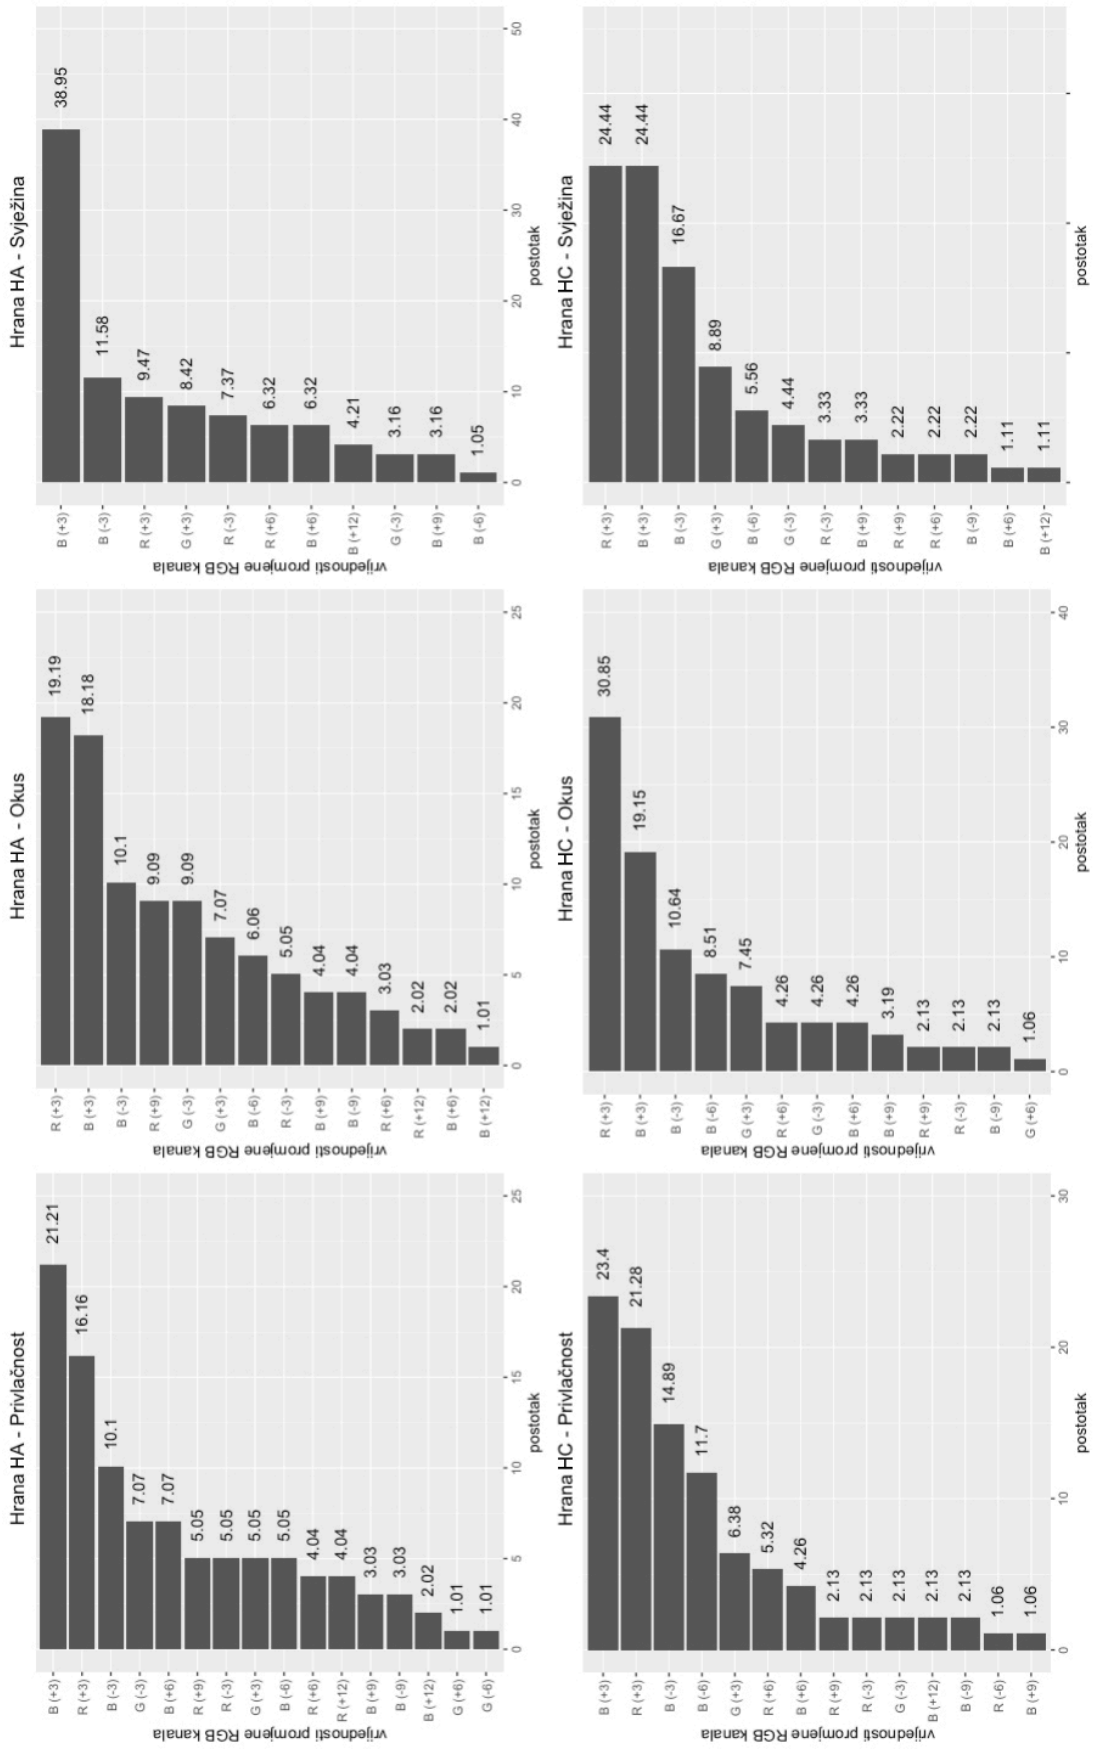
Kod fotografija hrane s varijacijama na cijeloj površini slike i samo na selekciji sudionici konzumenti su također trebali odabrati optimalnu varijantu promjene kanala digitalnog zapisa na atributima privlačnosti, okusa i svježine.

Kod fotografija hrane s varijacijama na cijeloj površini slike (Slika 81) možemo zamijetiti kako su varijante s tropostotnim oslabljenjem i pojačanjem kanala digitalnog zapisa najčešće birane kao optimalne po pitanju ovih triju atributa. Najprivlačnijom varijantom fotografije HA najčešće je birana ona s tropostotnim pojačanjem plavog kanala (21.21%); najukusnijim varijantama najčešće su proglašene one s tropostotnim pojačanjem crvenog (19.19%) i plavog (18.18%) kanala, a najsvježijom varijantom najčešće je birana ona s tropostotnim pojačanjem plavog kanala (38.95%). U slučaju fotografije HC, najprivlačnijim varijantama su najčešće birana one s tropostotnim pojačanjem plavog (23.4%), kao i crvenog (21.28%) kanala; najukusnijom varijantom najčešće je birana ona s tropostotnim pojačanjem crvenog (30.85%) kanala; a najsvježijim varijantama najčešće su odabrane one s tropostotnim pojačanjem crvenog (24.44%), kao i plavog (24.44%) kanala.

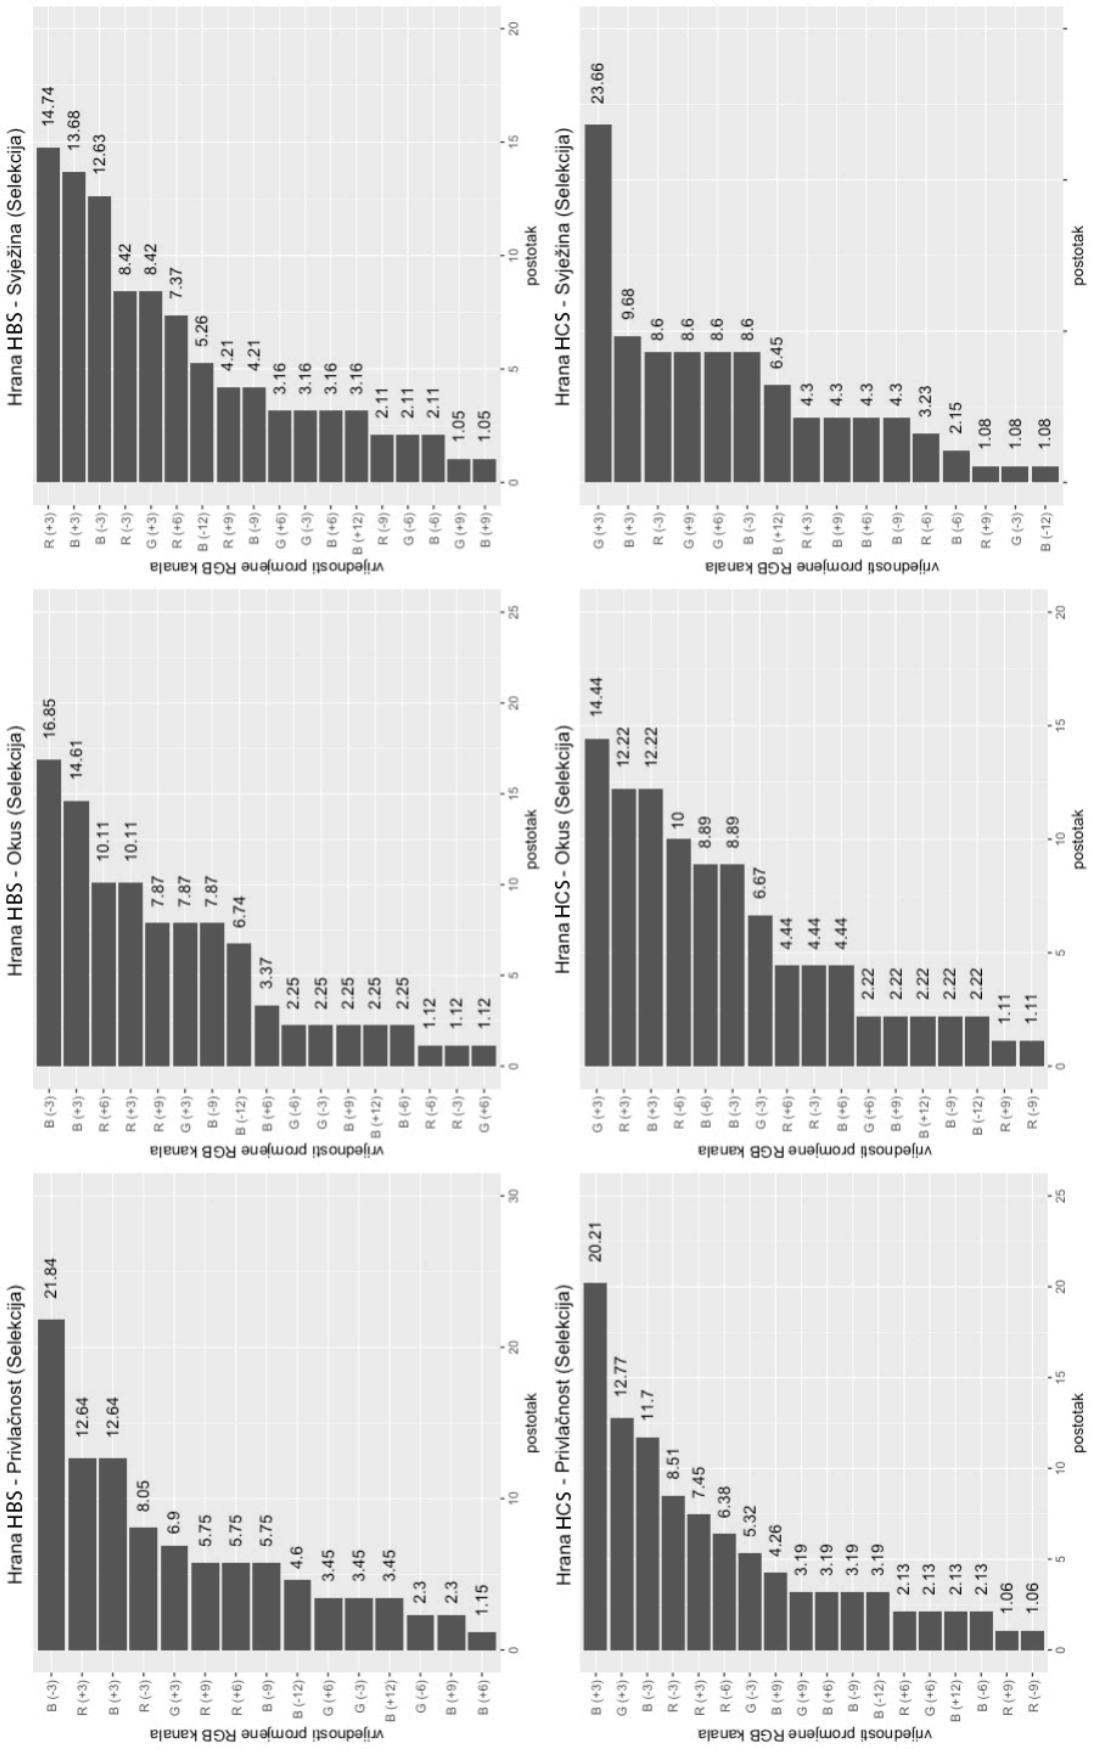
Kod fotografije hrane kod koje promjena digitalnog kanala nije obuhvaćala čitavu površinu (Slika 84), najprivlačnijom varijantom fotografije HBS najčešće je birana ona s tropostotnim oslabljenjem plavog kanala (21.84%), najukusnijim varijantama su u većem broju slučajeva birane one s tropostotnim oslabljenjem (16.85%), kao i pojačanjem (14.61%) plavog kanala; dok su najsvježijim varijantama najčešće birane one s tropostotnim pojačanjem crvenog (14.74%), kao i tropostotnim pojačanjem (13.68%) i oslabljenjem (12.63%) plavog kanala. U slučaju fotografija hrane sa selekcijom HCS, najprivlačnijom varijantom je najčešće birana ona s tropostotnim pojačanjem plavog kanala (20.21%), dok su najukusnijim varijantama najčešće birane one s tropostotnim pojačanjem zelenog (14.44%), crvenog (12.22%) i plavog (12.22%) kanala, a najsvježijom varijantom je najčešće birana ona s tropostotnim pojačanjem zelenog kanala (23.66%).



Slika 80 Učestalost odabira uzoraka pejzaža na atributu privlačnosti



Slika 81 Učestalost odabira uzoraka fotografija hrane bez selekcije na atributima privlačnosti, okusa i svježine



Slika 82 Učestalost odabira uzoraka fotografija hrane sa selekcijom na atributima privlačnosti, okusa i svježine

4.2.3. Procjene prikupljene u četvrtoj fazi istraživanja – metamerija

Dobiveni statistički rezultati općenito potvrđuju rezultate ispitivanja provedenih kroz četvrtu fazu ispitivanja, tj. istraživanje zadržavanja ikoničnosti fotografskih slika u metamerijskim uvjetima konzumiranja.

4.2.3.1. Rangiranje uzoraka prema kriteriju sličnosti s originalom

S ciljem provjere mogućnosti optimalnog zadržavanja ikoničnosti fotografske slike u metamerijskim uvjetima konzumiranja, odnosno, konzumiranje u različitim svjetlosnim uvjetima (*daylight, storelight, homelight*) korištenjem kućice za promatranje pod različitim izvorima svjetla Gretag MacBeth Judge II, odnosno, putem metode memorijskog vizualnog usuglašavanja, devet eksperata je unutar svakog od motiva rangiralo svaku od varijacija originalnih fotografija u svakom od tri metamerijska uvjeta, pri čemu je najmanji rang podrazumijevao najveću sličnost varijacije s originalnom fotografijom. Za svaki od fotografskih uzoraka izračunata je suma dodijeljenih rangova od strane devet eksperata, a uzorkom s najvećom sličnošću originalnoj fotografiji smatran je onaj s najmanjom sumom rangova. U Tablica 37 istaknuti su upravo ti uzorci u tri različita metamerijska uvjeta za svaku od originalnih fotografija.

Tablica 37 Rangovi kod fotografija prema zadržavanju ikoničnosti u odnosu na original kod tri različita izvora svjetla

	Daylight	Storelight	Homelight
Ženski portret PŽ	+3B (11)	+6B (21)	+3B (21)
Ženski portret (selekcija) PŽS	-3B (30)	-3R (23)	-3R (29)
Muški portret PM	+3B (21)	+3B (21)	+6B (19)
Muški portret (selekcija) PMS	-3R / +3G (30)	+3B (32)	-3R (24)
Dječji portret PD	+3B (21)	+3B (15)	+6B (20)
Dječji portret (selekcija) PDS	+3B (28)	+3B (19)	+3B (20)
Pejzaž LA	+3R (35)	+3B (17)	+3B (18)
Pejzaž LB	+3B (41)	+3B (45)	+3B (45)
Pejzaž LC	-3R (41)	+6B (34)	+3B (42)
Hrana HA	+3R (20)	+3B (25)	+3R (25)
Hrana HBS (selekcija)	+6B (45)	+3B (53)	+6B (41)
Hrana HC	+3R (14)	+3R (18)	+3R (22)
Hrana HCS (selekcija)	-3B (51)	-3R (33)	-3B (37)

Napomena. U zagradi su prikazane ukupne sume rangova eksperata

Kod ženskih, muških, kao i dječjih portreta kod kojih su promjene kanala digitalnog zapisa izvršene na čitavoj površini možemo primijetiti da su uzorci s tropostotnim ojačavanjem plavog kanala u većini slučajeva procijenjeni najsličnijim originalnoj fotografiji u sva tri metamerijska uvjeta. Iznimno, šestpostotna ojačavanja plavog kanala ženskog portreta u storelight uvjetu te muškog portreta u homelight uvjetu imali su najveću procjenu sličnosti s originalom. Kod ženskih portreta kod kojih je promjena kanala bila ograničena na područje lica, tropostotno slabljenje crvenog kanala u storelight i homelight uvjetu, odnosno, tropostotno slabljenje plavog kanala u daylight uvjetu je imalo najveće procjene sličnosti. Kod muških portreta sa selekcijom, tropostotna slabljenje crvenog, kao i tropostotno pojačavanje zelenog kanala su imali podjednako sumu rangova, odnosno podjednaku procjenu sličnosti u daylight uvjetu, dok su uzorci s tropostotnim pojačanjem plavog kanala u storelight uvjetu, odnosno, tropostotno oslabljivanje crvenog kanala u homelight uvjetu imali najveću procjenu sličnosti originalu. Kod dječjih portreta sa selekcijom, tropostotno pojačavanje plavog kanala je u sva tri uvjeta smatrano najsličnijim originalu.

Kod sva tri pejzaža u homelight uvjetu, kao i kod pejzaža A i pejzaža B u storelight uvjetu, uzorci s tropostotnim pojačavanje plavog kanala procijenjeni su kao najsličniji originalu, dok je kod pejzaža C u storelight uvjetu šestpostotno pojačanje plavog kanala smatrano najsličnijim. U daylight uvjetu, tropostotno pojačavanje crvenog kanala kod pejzaža A, odnosno tropostotno oslabljivanje crvenog kanala kod pejzaža C, kao i tropostotno pojačavanje plavog kanala kod pejzaža B smatrano je najsličnijim originalu.

Kod fotografija hrane u kojima je promjena kanala izvršena na čitavoj površini možemo primijetiti kako je tropostotno pojačanje crvenog kanala smatrano najsličnijim originalu u daylight i homelight uvjetu kod fotografije A i C, kao i u storelight uvjetu kod fotografije C. Jedino je tropostotno pojačanje plavog kanala u storelight uvjetu kod fotografija A i B, te šestpostotno pojačanje plavog kanala u daylight i homelight uvjetu kod fotografije B procijenjeno kao najsličnije originalu. Kod fotografije hrane kod koje je promjena kanala izvršena na ograničenom dijel površine, tropostotno oslabljivanje plavog kanala u daylight i homelight uvjetu, kao i tropostotno oslabljivanje crvenog kanala storelight uvjetu bilo je najsličnije originalu.

4.2.3.2. Odabir najprivlačnijih uzoraka za svaki od tri setova fotografija – portret, pejzaž, fotografija hrane

Osim rangiranja svih varijacija fotografija unutar svakog od korištenih motiva, zadatak eksperata je bio i da unutar svakog od setova, kao i unutar svakog od tri metamerijska uvjeta,

odaberu i najprivlačniju varijaciju. Svakoj varijaciji je dodijeljena vrijednost jedan ako je bila odabrana od strane eksperta, odnosno nula ako nije bio odabrana te su sumirani odabiri svih devet eksperata za svaku od varijacija. Svaka od varijacija mogla je imati procjenu privlačnosti u rasponu od 0-9. (Tablica 38) Varijacije koje su ostvarile isti broj bodova kao najviši navedene su jedne za drugima u istom redu. Varijacije koje su ostvarile manji broj bodova nisu navedene u tablici. U zagradi je naveden ostvaren broj bodova od ukupno 9 kao najviši, a taj broj bodova ostvario je svaki navedeni uzorak. (npr. -3R, +3B (2/9), znači da je varijacija tropostotnog oslabljivanja crvenog kanala i varijacija tropostotnog pojačavanja plavog kanala za taj motiv ostvarila jednak i ujedno najviši broj bodova od ukupno 9 mogućih).

Tablica 38 Prikaz izbora najprivlačnijih varijacija po motivu i izvoru svjetla od strane eksperata

Motiv	Najprivlačnija varijacija za Daylight	Najprivlačnija varijacija za Storelight	Najprivlačnija varijacija za Homelight
Ženski portret PŽ	+3B (4/9)	+3B (3/9)	+3B (4/9)
Ženski portret PŽS (selekcija)	-3R / -6B (3/9)	-3B (3/9)	+3R / +3B (3/9)
Muški portret PM	+3B (3/9)	+3R / +3B (3/9)	+3B (3/9)
Muški portret PMS (selekcija.)	-3R (3/9)	+3B (5/9)	-3B (3/9)
Dječji portret PD	+3B (5/9)	+3B (4/9)	+3B (4/9)
Dječji portret PDS (selekcija)	+3R (4/9)	+3R (4/9)	+3R (3/9)
Pejzaž LA	+9B (3/9)	+6B (3/9)	+3B (4/9)
Pejzaž LB	-3B (2/9)	+3G (2/9)	-3R / +9B (2/9)
Pejzaž LC	+3R / +9R (2/9)	+3R (2/9)	-3G / -3B (2/9)
Hrana HA	+3R / -3G (3/9)	+6R / +6G / -3G / +12B (2/9)	+3R (3/9)
Hrana HBS (selekcija)	+3R (2/9)	+3G / -3B (2/9)	+3R (3/9)
Hrana HC	+3R (4/9)	+3R / +3B (3/9)	+3R / +6R / -3G (2/9)
Hrana HCS (selekcija)	-3R / +3B (2/9)	-3R (3/9)	-3G / +6G / +3B (2/9)

Kod Daylight izvora svjetla prevladavaju izmjene u crvenom i plavom kanalu kao najprivlačnije, s tim da kod motiva hrane za sve motive prevladava promjena crvenog kanala

dok kod motiva pejzaža prevladava izmjena plavog kanala, osim u slučaju muškog i dječjeg portreta sa selekcijom gdje prevladava varijacija za tropostotnim pojačanjem plavog kanala. Kod Storelight izvora svjetla sličan je rezultat kao i kod Daylight izvora, s tim da se kod motiva hrane i pejzaža pojavljuje izbor varijacija s promjenom u zelenom kanalu. Kod Homelight izvora svjetla najviše odstupa motiv hrane HCS gdje dominira varijacija s promjenom u zelenom kanalu, iako je jednak broj bodova ostvarila i jedna varijacija u plavom kanalu. Također kod pejzaža LC pod ovim izvorom svjetla dominiraju promjena u zelenom i plavom kanalu za razliku od Daylight i Storelight uvjeta gdje je dominirala promjena u crvenom kanalu. Da bi se mogla provesti ANOVA analiza sumiranjem rezultata tako je formirana i nova varijabla koja je imala teorijski raspon od 0-9. Tako formirana varijabla privlačnosti predstavljala je kriterijsku varijablu te su provedene tri dodatne 3x4 ANOVE, neovisno o motivu, kako bi se razmotrili glavni efekti kanala, vrijednosti promjene kanala, kao i njihov interakcijski učinak i uočile potencijalne razlike u različitim metamerijskim uvjetima. Na varijabli vrijednosti promjene kanala opet su zadržane razine promjene u granicama od +/-6 % s obzirom na to da u nekim od analiza nije bilo moguće izračunati aritmetičke sredine zbog manjeg broja uzoraka na širim granicama vrijednosti promjene pojedinih kanala digitalnog zapisa.

4.2.3.2.1. DAYLIGHT izvor svjetla

U daylight metamerijskom uvjetu (Tablica 39) utvrđena je značajnost glavnih efekata varijabli kanala ($F(2,139)=8.277$; $p=.000$) i vrijednosti promjene kanala ($F(3,139)=4.742$; $p=.004$), kao i efekta interakcije varijabli kanala i vrijednosti promjene kanala ($F(6,139)=1.821$; $p=.099$).

Tablica 39 Prikaz rezultata dvosmjerne 3x4 analize varijance u daylight metamerijskom uvjetu

	SS	*df*	*MS*	*F*	*p*
Model	38.09	11	3.463	3.811	.000
Intercept	58.516	1	58.516	64.397	.000
Kanal	15.043	2	7.521	8.277	.000
Vrijednost kanala	12.927	3	4.309	4.742	.004
Kanal * Vrijednost kanala	9.926	6	1.654	1.821	.099
Pogreška	126.308	139	.909		

Fotografije s promjenama crvenog, kao i plavog kanala digitalnog zapisa u daylight uvjetu smatrane su privlačnijima od onih s promjenama zelenog kanala, dok između fotografija s izmjenama crvenog i plavog kanala nije postojala statistički značajna razlika (Tablica 40, Tablica 41).

Tablica 40 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u daylight uvjetu ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	0.673	.132	0.412	0.934
G	0.212	.142	-0.070	0.493
R	1.000	.132	0.739	1.261

Tablica 41 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u daylight uvjetu s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	47	0.23	
B	52		0.67
R	52		1
p		1.000	0.083

Isto tako, fotografije s tropostotnim pojačanjem kanala u daylight uvjetu smatrane su privlačnijim od fotografija sa šestpostotnim pojačanjem, kao i oslabljenjem kanala, ali jednako privlačnim kao i fotografije s tropostotnim oslabljenjem kanala digitalnog zapisa, a koje se pak smatrane jednako privlačnim kao i fotografije sa šestpostotnim oslabljenjem, odnosno pojačanjem kanala (Tablica 42, Tablica 43).

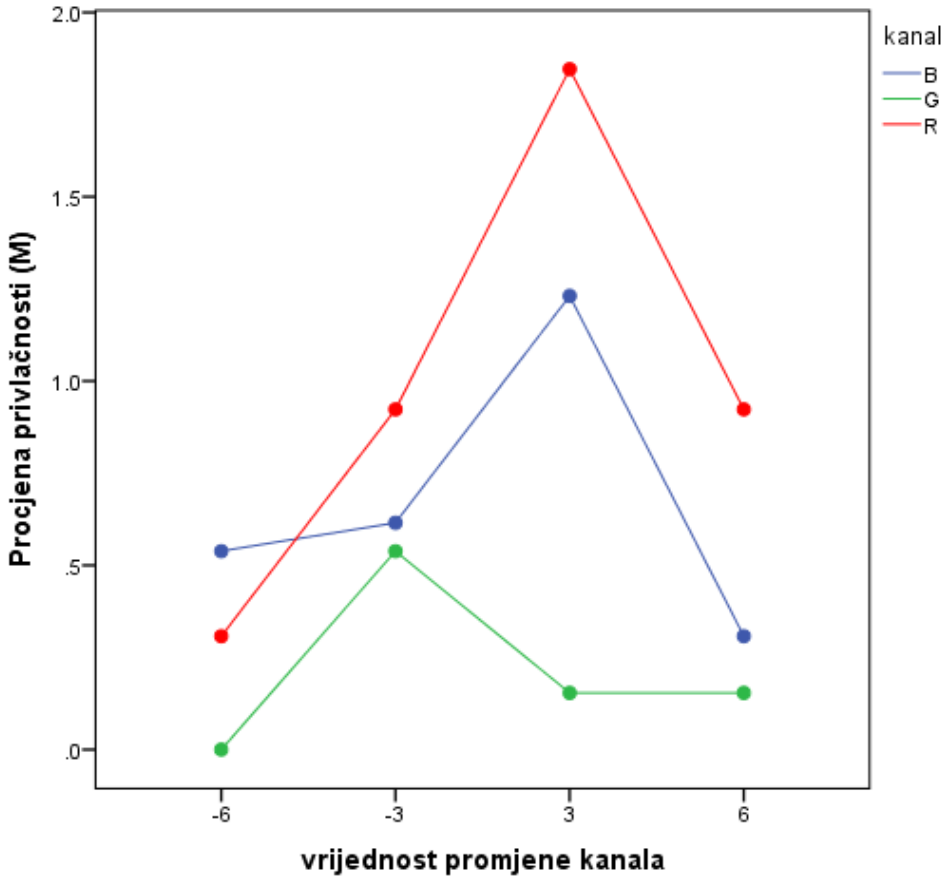
Tablica 42 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u daylight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	0.282	.168	-0.050	0.614
-3	0.692	.153	0.391	0.994
3	1.077	.153	0.775	1.379
6	0.462	.153	0.160	0.763

Tablica 43 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u daylight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi	
	N	1	2
-6	34	0.32	
6	39	0.46	
-3	39	0.69	0.69
3	39		1.08
p		0.251	.148

Na Slika 83 možemo vidjeti kako efekt varijable kanala u daylight metamerijskom uvjetu nije isti na svim razinama varijable vrijednosti promjene kanala. Kod fotografija sa šestpostotnim oslabljenjem kanala, veću privlačnost ostvaruju fotografije kojima je u tom stupnju promijenjen plavi kanal, dok na drugim vrijednostima promjene izmjene crvenog kanala dovode do veće privlačnost u odnosu na promjene plavog, osobito na uzorcima s tropostotnom promjenom kanala.



Slika 83 Prosječna privlačnost fotografija u daylight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa

4.2.3.2.2. STORELIGHT izvor svjetla

Slično kao i u daylight metamerijskom uvjetu, u storelight uvjetu (Tablica 44) utvrđena je značajnost glavnih efekata varijabli kanala ($F(2,139)=4.622$; $p=.011$) i vrijednosti promjene kanala ($F(3,139)=10.527$; $p=.000$), međutim, za razliku od daylight uvjeta, efekt varijable kanala na procjenu privlačnosti fotografija bio je podjednak na različitim razinama varijable vrijednosti promjene kanala $F(6,139)=1.491$; $p=.186$), odnosno, nije utvrđena značajnost efekta interakcije.

Tablica 44 Prikaz rezultata dvosmjerne 3x4 analize varijance u storelight metamerijskom uvjetu

	SS	*df*	*MS*	*F*	*p*
Model	39.751	11	3.614	4.579	.000
Intercept	62.154	1	62.154	78.760	.000
Kanal	7.295	2	3.648	4.622	.011
Vrijednost kanala	24.923	3	8.308	10.527	.000
Kanal * Vrijednost kanala	7.059	6	1.176	1.491	.186
Pogreška	109.692	139	.789		

Također, kao i u daylight uvjetu, u storelight metamerijskom uvjetu, fotografije s promjenama plavog, kao i crvenog kanala digitalnog zapisa smatrane su privlačnijima od onih s promjenama zelenog kanala, dok između fotografija s izmjenama plavog i crvenog kanala nije postojala statistički značajna razlika (Tablica 45, Tablica 46).

Tablica 45 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u storelight uvjetu ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	0.827	.123	0.583	1.070
G	0.327	.132	0.065	0.589
R	0.788	.123	0.545	1.032

Tablica 46 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u storelight uvjetu s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	47	0.36	
R	52		0.79
B	52		0.83
p		1	0.826

Nadalje, fotografije s tropostotnim pojačanjima kanala digitalnog zapisa smatrane su privlačnijima i od fotografija s tropostotnim oslabljenjem i od onih sa šestpostotnim pojačanjem kanala, a između kojih međusobno nije postajala statistički značajna razlika te od fotografija sa šestpostotnim oslabljenjem kanala. Fotografije s tropostotnim oslabljenjem kanala digitalnog zapisa također su smatrane privlačnijim od fotografija sa šestpostotnim oslabljenjem kanala, dok su fotografija sa šestpostotnim oslabljenjem i šestpostotnim pojačanjem kanala smatrane jednako privlačnima (Tablica 47, Tablica 48).

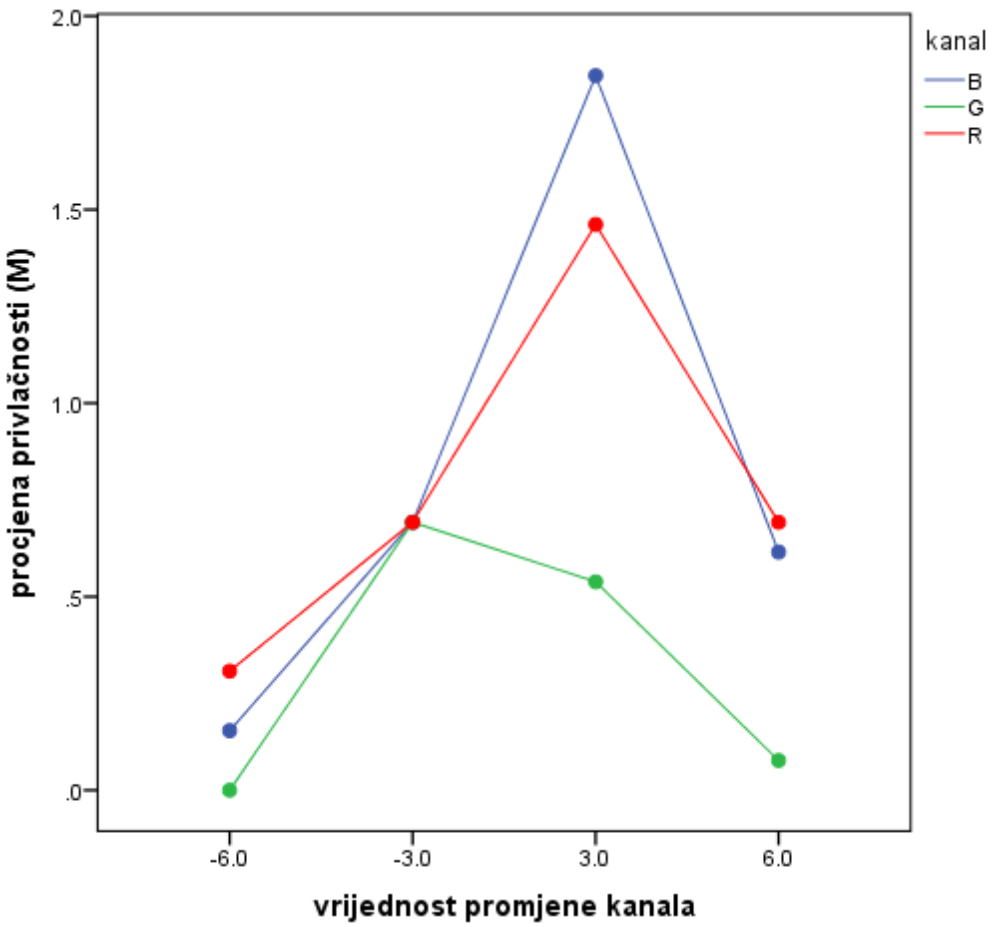
Tablica 47 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u storelight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	0.154	.156	-0.155	0.463
-3	0.692	.142	0.411	0.974
3	1.282	.142	1.001	1.563
6	0.462	.142	0.180	0.743

Tablica 48 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u storelight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi		
	N	1	2	3
-6	34	0.18		
6	39	0.46	0.46	
-3	39		0.69	
3	39			1.28
p		0.341	.442	1

Iako slika prosječne privlačnosti fotografija u storelight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa (Slika 84) na prvu može odavati dojam interaktivnog učinka, za razliku od daylight uvjeta, u storelight uvjetu nije utvrđena ovisnost efekta varijable kanala o razinama varijable vrijednosti promjena kanala digitalnog zapisa.



Slika 84 Prosječna privlačnost fotografija u storelight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa

4.2.3.2.3. HOMELIGHT izvor svjetla

Rezultati provedbe analize varijance u homelight uvjetu (Tablica 49) također su kao i u daylight uvjetu pokazali statističku značajnost glavnih efekata kanala ($F(2,139)=4.857$; $p=.009$) i vrijednosti promjene kanala ($F(3,139)=10.151$; $p=.000$), kao i njihovog interakcijskog učinka $F(6,139)=2.685$; $p=.017$)

Tablica 49 Prikaz rezultata dvosmjerne 3x4 analize varijance u homelight metamerijskom uvjetu

	SS	*df*	*MS*	*F*	*p*
Model	43.313	11	3.938	5.141	.000
Intercept	60.929	1	60.929	79.551	.000
Kanal	7.441	2	3.720	4.857	.009
Vrijednost kanala	23.324	3	7.775	10.151	.000
Kanal * Vrijednost kanala	12.337	6	2.056	2.685	.017
Pogreška	106.462	139	.766		

Fotografije s izmjenama plavog, kao i crvenog kanala procijenjene su privlačnijima od onih kod kojih je promijenjen zeleni kanal, dok između njih samih nije postojala razlika, tj. smatrane su jednako privlačnima (Tablica 50, Tablica 51).

Tablica 50 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u homelight uvjetu ovisno o kanalu digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
B	0.865	.121	0.625	1.105
G	0.327	.131	0.069	0.585
R	0.731	.121	0.491	0.971

Tablica 51 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u homelight uvjetu s obzirom na kanal digitalnog zapisa

		Subsetovi	
	N	1	2
G	47	0.36	
R	52		0.73
B	52		0.87
p		1	0.434

Nadalje, fotografije s tropostotnim pojačanjem kanala digitalnog zapisa procijenjene su privlačnijim i od fotografija s tropostotnim i šestpostotnim oslabljenjem, kao i od onih sa šestpostotnim pojačanjem kanala, a koje se međusobno nisu statistički značajno razlikovale, odnosno, procijenjene su jednako privlačnima (Tablica 52, Tablica 53).

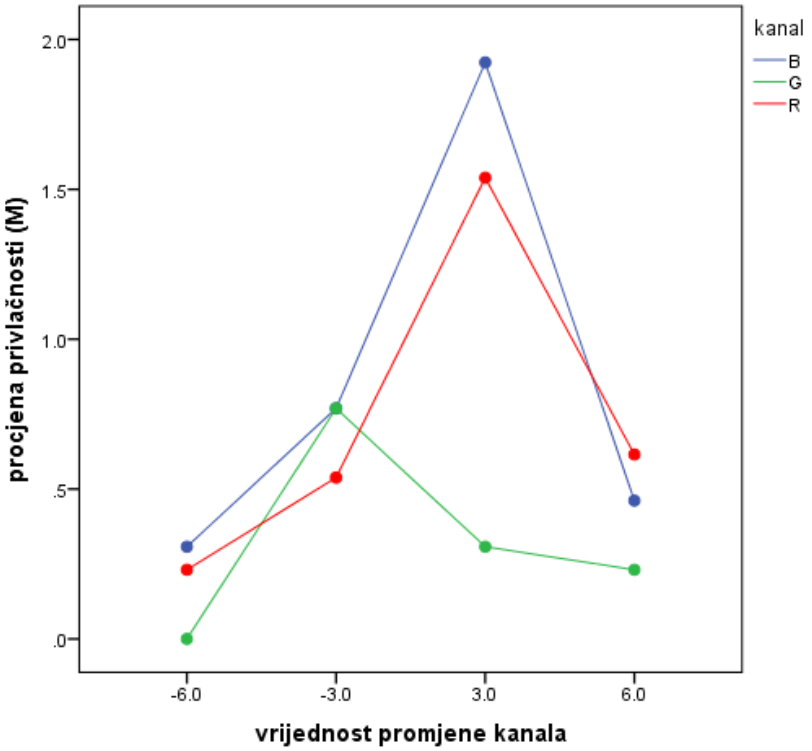
Tablica 52 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u homelight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa

			IP	
	M	*SE*	*IP donja granica*	*IP gornja granica*
-6	0.179	.154	-0.125	0.484
-3	0.692	.140	0.415	0.969
3	1.256	.140	0.979	1.533
6	0.436	.140	0.159	0.713

Tablica 53 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u homelight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa

		Subsetovi	
	N	1	2
-6	34	0.21	
6	39	0.44	
-3	39	0.69	
3	39		1.26
p		0.060	1

Kao što možemo vidjeti na Slika 85, efekt varijable kanala na procjenu privlačnosti ovisio je o razinama varijable vrijednosti promjene kanala digitalnog zapisa u homelight metamerijskom uvjetu. Razlika između promjena plavog i crvenog kanala digitalnog zapisa u kontekstu procjene privlačnosti bila je najviše izražena u slučaju tropostotnog pojačavanja kanala i to u korist promjene plavog kanala, dok su razlike u privlačnosti na drugim razinama bile manje, a u slučaju šestpostotnog pojačavanja kanala promjene crvenog kanala su rezultirale nešto višim procjenama privlačnosti od promjena plavog kanala. Isto tako, promjene zelenog kanala, koje su generalno imale najniže procjene privlačnosti neovisno o vrijednostima promjene, u slučaju tropostotnog oslabljivanja kanala, imale su istu procjenu privlačnosti kao i promjene plavog kanala digitalnog zapisa.



Slika 85 Prosječna privlačnost fotografija u homelight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa

4.3. Mjerna ispitivanja

U ovoj se fazi istraživanja mjerno određuju promjene boja testnih fotografskih slika promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa fotografskih slika odabranih u drugoj fazi istraživanja. Temeljem mjerenja L, a i b vrijednosti pojedinih boja određuju se ukupne razlike za određene srednje Lab vrijednosti boja promatrane karakteristične selekcije fotografske slike i za prosječne Lab vrijednosti cijele površine promatrane fotografske slike. Izračun cijelih površina za sva polja ukupnih zapisa slika testnih fotografija i tablice boja napravljen je pomoću izrađene skripte u Phytonu verzije 3.8.5. [81] [82]

Također se određuje ukupna promjena boja tablica boja dobivenih promjenama plavog, zelenog i crvenog kanala zapisa standardne X-Rrite u odnosu na standardnu (polaznu) tablicu boja. Koraci promjene za tablicu boja su 3% u granicama +/- 12%. Ukupne razlike boja se određuju kao ΔE_{00} razlike boja, a kao granica prihvatljivosti je određena razlika ΔE_{00} manja od 6. [13][18] Tablica boja s njenim varijacijama oslabljivanja i pojačavanja po kanalima nije uključena u ekspertnu analizu određivanja granica zadržavanja ikoničnosti te su prikazani rezultati za sve ukupne promjene razlike boja cijelih površina tablice boja u svim varijacijama oslabljivanja i pojačavanja kanala te za karakteristične boje tablice boja (svijetla i tamna boja kože, boja plavog neba, boja ljubičice, boja masline, primarne boje aditivne i suptraktivne sinteze boja, akromatske boje).

4.3.1. Mjerno određivanje promjene boja testnih fotografskih slika odabranih u drugoj fazi istraživanja i ukupne vrijednosti promjene cijele površine tablice boja

Prikazani su rezultati mjerenja L, a i b vrijednosti za cijele površine slika s i bez selekcije karakterističnih dijelova slika prema sintaktičkim i semantičkim karakteristikama pojedinih motiva odabranih u drugoj fazi istraživanja, a koje i dalje zadržavaju stupanj ikoničnosti u usporedbi s originalom. Dvanaestpostotna promjena kod svih motiva rezultirala je izbacivanjem većine uzoraka jer nisu ispunili zahtjev zadržavanja ikoničnosti. Kod uzoraka koji su ostali u istraživanju u slučaju dvanaestpostotnog oslabljivanja plavog kanala (Tablica 54a) ostala su četiri uzorka od kojih su dva uzorka imala ΔE_{00} u granici do 2 (fotografija hrane povrća i voća sa selekcijom (HBS i HCS)), jedan je uzorak bio u granici ΔE_{00} do 3.5 (pejzaž polja izrazitih boja (LC)), jedan je uzorak (tablica boja) ukupne promjene razlike boja imao rezultat ΔE_{00} = 4.65. Niti jedan uzorak preostao u ovoj promjeni nije prešao postavljenu granicu od ΔE_{00} = 6. Kod uzoraka koji su ostali u istraživanju u slučaju dvanaestpostotnog pojačavanja plavog kanala (Tablica 54b) ostalo je deset uzoraka od kojih su tri uzorka imala ΔE_{00} u granici do 2 (jedan od

2.06) (od čega su sve bile s promjenom izvršenom na selekciji – dječji portret sa selekcijom lica (PDS), fotografija hrane povrća sa selekcijom (HBS) i fotografija hrane voća sa selekcijom (HCS)). Dva uzorka su se jako približila granici $\Delta E_{00} = 6$, a dva su prešla dozvoljenu granicu - dječji portret sa selekcijom na cijeloj površini (PD) i morski pejzaž prevladavajućih tonova (LA). Tablica boja kod oslabljivanja ima $\Delta E_{00} = 4.6$, a kod pojačavanja $\Delta E_{00} = 4.4$.

Tablica 54: a) Plavi kanal oslabljen za 12% i b) Plavi kanal pojačan za 12%.
a)

MOTIV	-12B			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	-	-	-	-
PM	-	-	-	-
PMS	-	-	-	-
PD	-	-	-	-
PDS	-	-	-	-
LA	-	-	-	-
LB	-	-	-	-
LC	2.927523	0.451378	2.932978	-6.52921
HA	-	-	-	-
HBS	1.361814	0.073318	0.506401	-2.1077
HC	-	-	-	-
HCS	1.325661	0.078452	0.529335	-1.87551
TB	4.650683	0.386314	2.429032	-6.52176

b)

MOTIV	12B			
	ΔE00	ΔL	Δa	Δb
PŽ	5.509744	-0.32121	-2.10854	6.023169
PŽS	-	-	-	-
PM	5.97107	-0.31969	-2.20894	6.672985
PMS	-	-	-	-
PD	7.500831	-0.41519	-2.83913	8.35946
PDS	2.068835	-0.10461	-0.67417	2.379103
LA	7.070762	-0.66155	-4.5658	10.10968
LB	5.166924	-0.26989	-1.89433	5.387924
LC	2.613947	-0.50129	-3.05436	6.388408
HA	4.98695	-0.27744	-1.98417	6.088389
HBS	1.35904	-0.08197	-0.55627	2.099631
HC	5.36417	-0.36271	-2.53384	6.661807
HCS	1.192979	-0.08831	-0.57787	1.880123
TB	4.4211	-0.42049	-2.75955	6.268968

Kod uzoraka koji su ostali u istraživanju u slučaju dvanaestpostotnog pojačavanja crvenog kanala (Tablica 55) ostalo je četiri uzoraka od kojih su dva uzorka imala ΔE_{00} u granici do 6 (pejzaž sa zalaskom sunca (LB) i uzorak tablice boja (TB), a dva su prešla dozvoljenu granicu prihvatljivosti od ΔE_{00}=6 unatoč ispunjenju zahtjeva zadržavanja ikoničnosti (pejzaž prevladavajućih tonova (LA) i fotografija hrane ručka sa selekcijom na cijeloj površini(HA)).

Tablica 55 Crveni kanal s pojačanom vrijednosti za 12%.

MOTIV	+12R			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	-	-	-	-
PM	-	-	-	-
PMS	-	-	-	-
PD	-	-	-	-
PDS	-	-	-	-
LA	7.760615	-1.31762	-5.79368	-2.1194
LB	5.284467	-1.14082	-4.62451	-1.72476
LC	-	-	-	-
HA	7.40411	-1.72046	-6.99489	-2.57568
HBS	-	-	-	-
HC	-	-	-	-
HCS	-	-	-	-
TB	4.595086	-1.36486	-4.96125	-2.02603

Devetpostotna promjena s pojačanjem zelenog kanala (Tablica 56) je prva promjena koja je ostala u istraživanju jer su sve promjene zelenog kanala s dvanaestpostotnim promjenama izbačene. Ovdje su ostala četiri uzorka od kojih su čak tri bila u granicama ΔE_{00} =3.5.

Tablica 56 Zeleni kanal pojačan za 9%.

MOTIV	+9G			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	-	-	-	-
PM	-	-	-	-
PMS	2.974497	-1.10414	2.354418	-1.52537
PD	-	-	-	-
PDS	-	-	-	-
LA	-	-	-	-
LB	-	-	-	-
LC	4.907848	-2.87275	5.756913	-3.8884
HA	-	-	-	-
HBS	2.266813	-1.36732	2.577467	-1.65136
HC	-	-	-	-
HCS	2.323669	-1.26267	2.541661	-1.43603
TB	5.421945	-2.65997	5.079005	-3.57979

U slučaju devetpostotnog oslabljivanja plavog kanala (Tablica 57) ostali su svi uzorci osim ženskog portreta s promjenom na cijeloj površini slike (PŽ), od čega je pet uzoraka imalo ΔE_{00} u granici do 2 (portreti sa selekcijom (PŽS, PMS, i PDS), fotografija hrane povrća (HBS) i fotografija hrane voća (HCS)), dok su dva uzorka (dječji portret s promjenom na cijeloj površini slike (PD) i pejzaža s prevladavajućim tonovima (LA)), imali rezultat ΔE_{00} iznad 7, što prelazi postavljenu granicu prihvatljivosti od ΔE_{00}=6, ali može se objasniti plavom bojom mora i neba kod motiva pejzaža, i većom tolerancijom ispitanika konzumenata na promjene kod portreta djeteta općenito. U slučaju devetpostotnog pojačavanja plavog kanala rezultati prate tablicu oslabljivanja s tim da u ovom slučaju samo dječji portret (PD) prelazi granicu od ΔE_{00}=6, ali niti jedan uzorak nije izbačen.

Tablica 57 Plavi kanal oslabljen i pojačan za 9%.

MOTIV	-9B			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	1.348417	0.070472	0.453547	-1.69375
PM	5.242739	0.28845	1.911968	-6.07358
PMS	1.494357	0.076991	0.486139	-1.98614
PD	6.638795	0.374383	2.524082	-7.72841
PDS	1.369087	0.073058	0.47036	-1.82559
LA	7.645091	0.467719	3.332164	-8.21557
LB	3.626498	0.188089	1.309545	-4.11716
LC	2.208173	0.345702	2.235656	-4.93605
HA	5.450403	0.300762	2.042137	-6.58644
HBS	1.062737	0.056594	0.389933	-1.59957
HC	5.720965	0.328553	2.151422	-6.29051
HCS	1.01706	0.060654	0.407267	-1.42243
TB	3.451569	0.292583	1.847492	-4.773

MOTIV	+9B			
	ΔE00	ΔL	Δa	Δb
PŽ	4.878867	-0.27927	-1.86753	5.234907
PŽS	1.421866	-0.07622	-0.49115	1.668722
PM	5.04607	-0.27545	-1.84159	5.582971
PMS	1.664852	-0.0848	-0.52916	1.968111
PD	6.338752	-0.33916	-2.3802	6.967052
PDS	1.554857	-0.07836	-0.504	1.791956
LA	5.785545	-0.49306	-3.47736	7.759911
LB	3.958661	-0.20103	-1.3955	4.08598
LC	2.018561	-0.37313	-2.30183	4.833521
HA	3.995951	-0.21648	-1.57223	4.805596
HBS	1.052404	-0.06158	-0.41895	1.591335
HC	4.420583	-0.2783	-1.97894	5.230107
HCS	0.933632	-0.06542	-0.43256	1.41762
TB	3.557411	-0.3738	-2.20811	4.794149

U slučaju devetpostotnog oslabljivanja crvenog kanala (Tablica 58) pet uzoraka je izbačeno, a od preostalih uzoraka 3 uzorka ima ΔE_{00} u granici do 2 (svi sa selekcijom - ženski portret (PŽS), fotografija hrane povrća (HBS) i fotografija hrane voća (HCS)), dok su ostali uzorci imali rezultat ΔE_{00} u granici do 6. U slučaju devetpostotnog pojačavanja crvenog kanala izbačeno je šest uzoraka s tim da u ovom slučaju fotografija hrane ručka (HA) prelazi granicu od $\Delta E_{00} = 6$. Tablica boja u oba slučaja ima $\Delta E_{00} < 4$.

Tablica 58 Crveni kanal oslabljen i pojačan za 9%.

MOTIV	-9R			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	1.68621	0.408999	1.669582	0.644648
PM	-	-	-	-
PMS	2.208257	0.531036	2.166615	0.821554
PD	-	-	-	-
PDS	2.138477	0.453776	1.896587	0.70229
LA	5.219977	0.956944	4.422627	1.524231
LB	4.245939	0.805005	3.460045	1.221703
LC	3.409172	0.906984	3.853992	1.342886
HA	-	-	-	-
HBS	1.814141	0.743118	2.481785	1.052124
HC	-	-	-	-
HCS	1.955196	0.720256	2.530713	0.997943
TB	3.615287	1.051679	3.864945	1.670261

MOTIV	+9R			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	-	-	-	-
PM	-	-	-	-
PMS	-	-	-	-
PD	-	-	-	-
PDS	-	-	-	-
LA	**5.937161**	-0.99711	-4.4139	-1.59652
LB	4.131296	-0.85345	-3.48787	-1.2708
LC	3.353554	-0.96186	-3.85251	-1.42421
HA	6.01585	-1.3177	-5.47405	-1.97376
HBS	1.82135	-0.77078	-2.46104	-1.07876
HC	**5.731335**	-1.35306	-5.19145	-1.98892
HCS	1.888111	-0.73063	-2.40421	-1.00451
TB	3.549412	-1.09717	-3.76664	-1.61324

Kod šestpostotnih promjena vrijednosti oslabljivanja i pojačavanja plavog kanala (Tablica 59) niti jedan uzorak nije izbačen, ali niti jedan uzorak ne prelazi granicu od $\Delta E_{00} = 6$. U oba slučaja, kod oslabljivanja i kod pojačavanja plavog kanala čak pet uzoraka istih motiva u obje tablice (PŽS, PMS, PDS, LC, HBS, HCS) ima $\Delta E_{00} < 1$.

S manjim promjenama vrijednosti kanala povećava se broj uzoraka s vrijednostima promjene boja manjih od 1 što predstavlja odstupanje koje se ne zamjećuje dok se više ne pojavljuju niti uzorci koji prelaze granicu prihvatljivosti od $\Delta E_{00}=6$.

Tablica boja u oba slučaja ima $\Delta E_{00} < 3$.

Tablica 59 Plavi kanal oslabljen i pojačan za 6%.

MOTIV	-6B			
	ΔE00	ΔL	Δa	Δb
PŽ	5.213106	0.306388	1.833832	-5.37865
PŽS	0.918885	0.049187	0.302145	-1.12213
PM	3.639532	0.215556	1.244697	-3.97233
PMS	1.03318	0.05347	0.329765	-1.32471
PD	4.659844	0.283508	1.654874	-5.12668
PDS	0.951977	0.05048	0.319921	-1.21757
LA	5.089315	0.316087	2.270713	-5.45427
LB	2.491887	0.132727	0.86356	-2.73198
LC	1.498645	0.234711	1.497878	-3.29022
HA	3.818487	0.207103	1.393781	-4.37568
HBS	0.742976	0.038727	0.264367	-1.06919
HC	4.063717	0.210488	1.531149	-4.20589
HCS	0.702776	0.041029	0.277492	-0.95012
TB	2.573742	0.100419	1.394299	-3.25869

MOTIV	+6B			
	ΔE00	ΔL	Δa	Δb
PŽ	4.0501	-0.23785	-1.526	4.24522
PŽS	0.950751	-0.05122	-0.31746	1.108249
PM	3.639492	-0.18905	-1.28336	3.894623
PMS	1.098211	-0.05566	-0.34477	1.300276
PD	4.615306	-0.24975	-1.63595	4.945675
PDS	1.026996	-0.05153	-0.33067	1.186775
LA	4.150177	-0.32466	-2.29766	5.215645
LB	2.642083	-0.14252	-0.91887	2.68744
LC	1.396412	-0.24303	-1.51425	3.202025
HA	2.911927	-0.15187	-1.12725	3.397141
HBS	0.732107	-0.04049	-0.27707	1.057368
HC	3.245712	-0.18755	-1.37398	3.624306
HCS	0.657993	-0.04262	-0.28378	0.938008
TB	2.67724	-0.24048	-1.56524	3.380371

Kod šestpostotnih promjena vrijednosti oslabljivanja i pojačavanja crvenog kanala (Tablica 60) niti jedan uzorak nije izbačen, ali također niti jedan uzorak ne prelazi granicu od $\Delta E_{00} = 6$. U oba slučaja, vrlo slično kao i kod plavog kanala s ovim postotkom, ali malo viših promjena ΔE_{00}, kod oslabljivanja i kod pojačavanja crvenog kanala čak pet uzoraka istih motiva sa selekcijom u obje tablice (PŽS, PMS, PDS, HBS, HCS) ima $\Delta E_{00} < 2$ (najviši $\Delta E_{00}=1.40$ unutar ovih motiva) što znači vrlo malu razliku zamjetnu samo iskusnom promatraču. Kod pojačavanja crvenog kanala na promjeni cijele površine slike dva motiva imaju $\Delta E_{00} \approx 5$ dok svi ostali motivi u oba slučaja imaju $\Delta E_{00} < 5$. Tablica boja u oba slučaja ima $\Delta E_{00} < 3$.

Tablica 60 Crveni kanal oslabljen i pojačan za 6%.

MOTIV	-6R			
	ΔE00	ΔL	Δa	Δb
PŽ	5.042074	0.978847	4.074777	1.649195
PŽS	1.070091	0.277732	1.11726	0.434548
PM	3.987391	0.808001	3.397527	1.270748
PMS	1.408878	0.359277	1.441581	0.554682
PD	5.134607	0.965493	4.166972	1.539381
PDS	1.382847	0.306351	1.265631	0.468995
LA	3.682901	0.656186	2.982023	1.030101
LB	2.85419	0.539138	2.282713	0.82142
LC	2.330102	0.610176	2.581997	0.906177
HA	4.41282	0.919316	3.949908	1.41465
HBS	1.233596	0.500748	1.652054	0.706846
HC	3.986234	0.952011	3.758139	1.435259
HCS	1.330158	0.484811	1.686238	0.668667
TB	2.442759	0.718797	2.455694	1.360996

MOTIV	+6R			
	ΔE00	ΔL	Δa	Δb
PŽ	4.414854	-0.89839	-3.76766	-1.35261
PŽS	0.858517	-0.28644	-1.10247	-0.43686
PM	3.805592	-0.80211	-3.38486	-1.23298
PMS	1.162391	-0.37058	-1.42344	-0.55895
PD	4.844718	-0.96285	-4.10491	-1.48019
PDS	1.144493	-0.31351	-1.25116	-0.47849
LA	4.003112	-0.66155	-2.96202	-1.05533
LB	2.847877	-0.55978	-2.31894	-0.81351
LC	2.272923	-0.63172	-2.54253	-0.93803
HA	4.298396	-0.90274	-3.75933	-1.35018
HBS	1.229222	-0.50751	-1.62858	-0.71092
HC	4.130039	-0.93869	-3.65745	-1.37423
HCS	1.310576	-0.49299	-1.647	-0.67666
TB	2.58334	-0.75545	-2.70136	-1.16916

Kod šestpostotnih promjena vrijednosti oslabljivanja i pojačavanja zelenog kanala (Tablica 61) u oba slučaja ΔE_{00}>6 za po tri uzorka (u obje tablice kod PD i LA, kod oslabljivanja u fotografiji hrane ručka (HA), a kod pojačavanja u fotografiji ženskog portreta (PŽ) koja je u slučaju oslabljivanja izbačena jer je procijenjeno da ne zadržava ikoničnost). U tablici s pojačanjem vrijednosti kanala niti jedan uzorak nije izbačen. Uzorak pejzaža izrazitih boja u obje tablice zadržao je vrijednost ΔE_{00} do 3.5, dok su svi ostali uzorci od ΔE_{00}=4 na više.

Tablica boja kod ove promjene u slučaju pojačavanja ima ΔE_{00}=3.93, a u slučaju oslabljivanja ΔE_{00}=4.07.

Tablica 61 Zeleni kanal oslabljen i pojačan za 6%.

MOTIV	-6G			
	ΔE00	ΔL	Δa	Δb
PŽ	-	-	-	-
PŽS	-	-	-	-
PM	5.950841	2.135696	-4.55768	3.14396
PMS	-	-	-	-
PD	7.774295	2.758034	-5.79824	4.054087
PDS	1.851117	0.682701	-1.48377	0.95467
LA	7.00533	2.648083	-5.46505	3.969988
LB	4.516721	1.465193	-3.11317	2.09976
LC	3.436337	1.902222	-3.96603	2.607409
HA	6.900409	2.532951	-5.313	3.540761
HBS	1.612122	0.907195	-1.77596	1.112766
HC	-	-	-	-
HCS	1.640326	0.834113	-1.73968	0.959484
TB	4.075363	1.815355	-3.87196	2.551149

MOTIV	+6G			
	ΔE00	ΔL	Δa	Δb
PŽ	7.054658	-2.4911	5.058002	-3.57961
PŽS	1.629145	-0.58832	1.26603	-0.8293
PM	5.86467	-2.12919	4.381873	-3.00938
PMS	1.979822	-0.72654	1.561332	-0.9981
PD	7.454117	-2.71859	5.53981	-3.83126
PDS	1.882037	-0.67885	1.436268	-0.94836
LA	6.988038	-2.59156	5.167129	-3.85245
LB	4.124818	-1.46995	2.963026	-2.07477
LC	3.319309	-1.89871	3.843341	-2.58721
HA	5.786166	-2.28543	4.65555	-3.16333
HBS	1.540143	-0.90352	1.713306	-1.09432
HC	5.850321	-2.35442	4.755131	-3.20674
HCS	1.581002	-0.83372	1.690953	-0.95026
TB	3.931247	-1.79001	3.649447	-2.37331

Kod tropostotnih promjena vrijednosti oslabljivanja i pojačavanja crvenog kanala (Tablica 62) u oba slučaja $\Delta E_{00} < 3$ za sve uzorke. Čak pet uzoraka istih motiva sa selekcijom u obje tablice (PŽS, PMS, PDS, HBS, HCS) ima $\Delta E_{00} < 1$, četiri uzorka ima $\Delta E_{00} \leq 2$ (kod oslabljivanja svi motivi pejzaža, a kod pojačavanja muški portret (PM) i pejzaži LB i LC).

Tablica boja kod ove promjene u slučaju pojačavanja ima ΔE_{00}=0.65, a u slučaju oslabljivanja ΔE_{00}=1.32.

S obzirom na promjenu od 3% rezultati promjene boja ΔE_{00} su očekivani.

Tablica 62 Crveni kanal oslabljen i pojačan za 3%.

MOTIV	-3R			
	ΔE00	ΔL	Δa	Δb
PŽ	2.589862	0.471365	2.015986	0.703071
PŽS	0.521024	0.140954	0.563818	0.214751
PM	2.125989	0.409235	1.73615	0.614522
PMS	0.691119	0.18244	0.717467	0.278189
PD	2.70553	0.498225	2.112388	0.780273
PDS	0.677088	0.154986	0.628535	0.229986
LA	2.002606	0.334574	1.501294	0.526307
LB	1.473639	0.270586	1.126142	0.432408
LC	1.251065	0.312087	1.29118	0.460509
HA	2.326256	0.457464	2.00302	0.658568
HBS	0.661682	0.251998	0.827168	0.353972
HC	2.155427	0.481007	1.909337	0.661426
HCS	0.71383	0.243343	0.842647	0.333504
TB	1.329662	0.355753	1.318709	0.422075

MOTIV	+3R			
	ΔE00	ΔL	Δa	Δb
PŽ	2.724727	-0.47868	-2.14947	-0.70971
PŽS	0.456473	-0.14134	-0.54516	-0.21035
PM	2.081136	-0.38426	-1.70739	-0.58474
PMS	0.625482	-0.1788	-0.70623	-0.26587
PD	2.617636	-0.47458	-2.06094	-0.7271
PDS	0.607598	-0.15162	-0.61416	-0.22414
LA	2.029138	-0.32709	-1.45387	-0.51912
LB	1.468583	-0.26855	-1.13386	-0.38101
LC	1.216173	-0.30791	-1.25895	-0.4558
HA	2.292894	-0.45329	-1.91911	-0.66789
HBS	0.652126	-0.24758	-0.80762	-0.34675
HC	2.162401	-0.47736	-1.84302	-0.68934
HCS	0.696	-0.2416	-0.81518	-0.32998
TB	1.4567	-0.39761	-1.38576	-0.45776

Kod tropostotnih promjena vrijednosti oslabljivanja i pojačavanja zelenog kanala (Tablica 63) u oba slučaja $\Delta E_{00} \leq 4.13$ za sve uzorke. Čak pet uzoraka istih motiva sa selekcijom u obje tablice kao i kod crvenog kanala s istim postotkom promjene (PŽS, PMS, PDS, HBS, HCS) ima $\Delta E_{00} < 1$. Jedan uzorak (pejzaž izrazitih boja (LC) ima $\Delta E_{00} \leq 2$.

Tablica boja kod ove promjene u slučaju pojačavanja ima ΔE_{00}=2.11, a u slučaju oslabljivanja ΔE_{00}=2.20.

S obzirom na promjenu od 3% rezultati promjene boja ΔE_{00} su očekivani, ali su i viši nego kod crvenog i plavog kanala za isti postotak promjene.

Tablica 63 Zeleni kanal oslabljen i pojačan za 3%.

MOTIV	-3G			
	ΔE00	ΔL	Δa	Δb
PŽ	3.966466	1.354703	-2.82992	1.991113
PŽS	0.760319	0.2952	-0.64896	0.423199
PM	3.186391	1.073758	-2.25359	1.554796
PMS	0.985142	0.367773	-0.80921	0.51156
PD	4.132948	1.375406	-2.84999	2.007774
PDS	0.954633	0.342017	-0.73725	0.471246
LA	3.691911	1.329353	-2.71026	1.975634
LB	2.402676	0.753647	-1.59351	1.045946
LC	1.772014	0.956753	-1.97849	1.309813
HA	3.592005	1.26798	-2.62992	1.769008
HBS	0.846112	0.456318	-0.88882	0.558827
HC	3.392749	1.240209	-2.56885	1.721678
HCS	0.853034	0.417533	-0.86396	0.477668
TB	2.209183	0.897116	-1.9549	1.412388

MOTIV	+3G			
	ΔE00	ΔL	Δa	Δb
PŽ	4.119893	-1.37208	2.857532	-1.85662
PŽS	0.792109	-0.28972	0.625683	-0.40558
PM	3.161791	-1.0484	2.241356	-1.48546
PMS	0.973918	-0.35727	0.766533	-0.48453
PD	4.078189	-1.34534	2.866081	-1.89872
PDS	0.936491	-0.3318	0.702195	-0.45326
LA	3.622906	-1.28686	2.579766	-1.91351
LB	2.094686	-0.71097	1.437174	-0.93562
LC	1.705231	-0.93398	1.904081	-1.27728
HA	3.237151	-1.19848	2.44752	-1.65015
HBS	0.805393	-0.44285	0.845628	-0.53907
HC	3.261597	-1.20492	2.477568	-1.61982
HCS	0.823284	-0.40878	0.834661	-0.46529
TB	2.110927	-0.92302	1.771028	-1.28864

Kod tropostotnih promjena vrijednosti oslabljivanja i pojačavanja plavog kanala (Tablica 64) u oba slučaja $\Delta E_{00} \leq 2.75$ za sve uzorke. Čak pet uzoraka istih motiva sa selekcijom u obje tablice (PŽS, PMS, PDS, HBS, HCS) i jedan uzorak bez selekcije (pejzaž s izrazitim bojama (LC)) imaju $\Delta E_{00} < 1$. Kod oslabljivanja dva uzorka bez selekcije (PM i LB) imaju $\Delta E_{00} \leq 2$, a kod pojačavanja tri uzorka (PM, LB i HC).

Tablica boja kod ove promjene u slučaju pojačavanja ima ΔE_{00}=1.4, a u slučaju oslabljivanja .ΔE_{00}=1.17.

Promjena od tri posto boja ΔE_{00} u plavom kanalu slična je promjeni od tri posto u crvenom kanalu, dok zeleni kanal pokazuje dosta veće promjene.

Tablica 64 Plavi kanal oslabljen i pojačan za 3%.

MOTIV	-3B			
	ΔE00	ΔL	Δa	Δb
PŽ	2.590497	0.148447	0.837861	-2.56697
PŽS	0.485989	0.025113	0.162634	-0.56395
PM	1.939311	0.111811	0.612598	-1.96592
PMS	0.543209	0.026558	0.167956	-0.64858
PD	2.471475	0.135022	0.82357	-2.53168
PDS	0.501871	0.026366	0.160012	-0.59684
LA	2.570866	0.169914	1.168962	-2.73358
LB	1.310245	0.068483	0.457337	-1.33045
LC	0.833517	0.123402	0.756592	-1.66604
HA	2.073012	0.106924	0.725051	-2.21747
HBS	0.417461	0.019716	0.134597	-0.53797
HC	2.18888	0.11428	0.766559	-2.15676
HCS	0.3931	0.020806	0.141509	-0.47359
TB	1.175149	0.090076	0.561359	-1.48712

MOTIV	+3B			
	ΔE00	ΔL	Δa	Δb
PŽ	2.759765	-0.14293	-1.08853	2.714001
PŽS	0.483804	-0.02536	-0.16272	0.549388
PM	1.99639	-0.09178	-0.71769	1.967123
PMS	0.555207	-0.02776	-0.16949	0.639677
PD	2.588726	-0.12138	-0.95493	2.550657
PDS	0.513621	-0.0248	-0.16106	0.577901
LA	2.293766	-0.17018	-1.17361	2.642713
LB	1.347072	-0.05888	-0.48591	1.298622
LC	0.788106	-0.11693	-0.73723	1.580464
HA	1.706843	-0.08172	-0.62769	1.851576
HBS	0.408214	-0.01904	-0.13684	0.521123
HC	1.909464	-0.10722	-0.76968	1.952446
HCS	0.373784	-0.02058	-0.13816	0.45751
TB	1.40074	-0.12396	-0.86018	1.779529

Iz navedenih rezultata vidljivo je da su vrijednosti ukupne promjene boja ΔE_{00} vidljive najviše na najvećim promjenama pojačavanja ili oslabljivanja kanala, a granicu prihvatljivosti od šest prelaze tek kod devetpostotne promjene.

S obzirom na to da su u ovu fazu ušle samo fotografije koje su ostale nakon druge faze istraživanja ovdje su prikazani rezultati tih fotografija, a od njih prvo prekoračenje granice $\Delta E_{00} = 6$ kod devetpostotnih promjena vidljivo je kod pojačanja crvenog kanala na primjeru morskog pejzaža s prevladavajućom bojom (LA) za 0.01, zatim za 0.33 kod pojačanog plavog kanala na primjeru dječjeg portreta (PD), 0.63 kod dječjeg portreta i 1.64 kod morskog pejzaža (LA) s oslabljivanjem plavog kanala. Zatim za 1.76 morski pejzaž (LA) i 1.4 hrana ručka (HA) kod dvanaestpostotnog pojačanja crvenog kanala, za 1.07 morski pejzaž (LA) i za 1.5 dječji portret (PD) kod dvanaestpostotnog pojačavanja plavog kanala. Kod dvanaestpostotnog oslabljenja plavog kanala najbolji rezultat ostvarila je fotografija hrane voća sa selekcijom (HCS) s rezultatom $\Delta E_{00} = 1.33$.

Tablica boja kod promjene u zelenom kanalu ostvarila je najveći rezultat ukupne promjene boja kod devetpostotnog pojačanja zelenog kanala s rezultatom ΔE_{00}=5.42, dok devetpostotno smanjenje te dvanaestpostotno smanjenje i pojačanje zelenog kanala nisu ušli u mjerenje zbog druge faze istraživanja u kojoj nisu zadovoljile kriterij zadržavanja ikoničnosti. U crvenom kanalu najveći rezultat od ΔE_{00}=4.6 zabilježen je kod dvanaestpostotnog pojačanja dok dvanaestpostotno smanjenje nije zadovoljilo kriterij zadržavanja ikoničnosti. Kod plavog kanala najveći rezultat ΔE_{00}=4.65 zabilježen kod dvanaestpostotnog smanjenja, a kod pojačanja zabilježen je rezultat od ΔE_{00}=4.4.

Općenito, sve fotografije sa selekcijom na ukupnoj površini ostvarile su bolje rezultate u ukupnoj razlici boja od onih na kojima je mijenjana cijela površina slike.

4.3.2. Mjerno određivanje promjene boja pojedinih odabranih boja standardne tablice boja

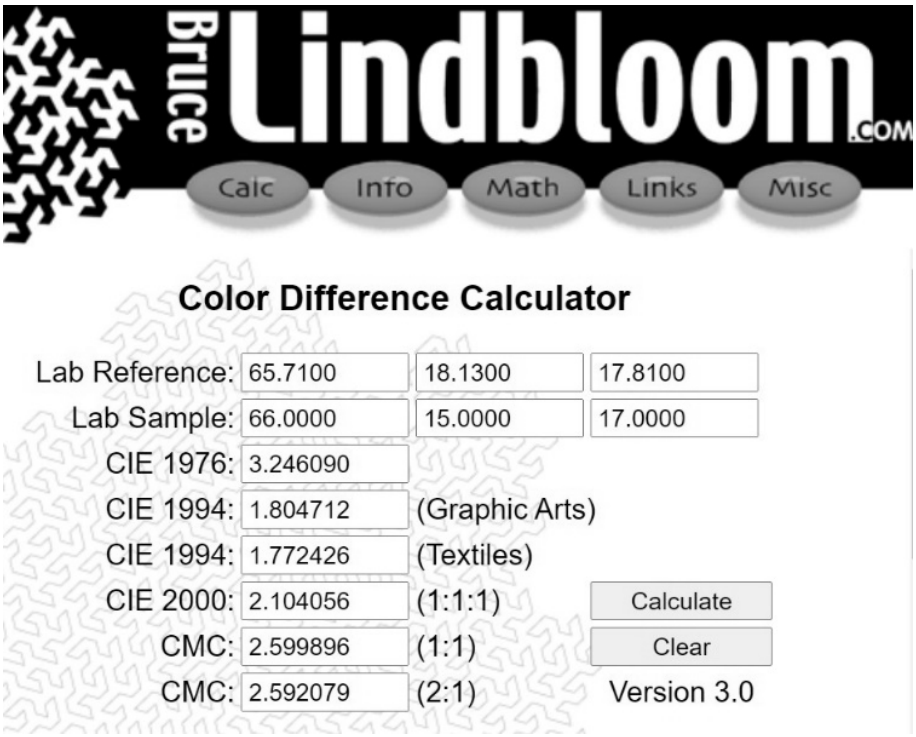
Promjene boja standardne tablice boja na cijeloj površini slike s promjenama izvedenim u koracima od tri posto u granicama +/- dvanaest posto prikazane su u Tablica 65. Zeleno su označene vrijednosti kanala za ukupan izračun svih boja tablice boja koje pokazuju najmanje odstupanje u razlici boja (1.1 – 1.4), svijetlo narančasto one promjene koje su blizu granice prihvatljivosti $\Delta E_{00} = 6$, a crvenom bojom one promjene koje su iznad granice prihvatljivosti $\Delta E_{00} = 6$ te nisu prihvatljive. Najmanje promjene ΔE_{00} uočene su kod tropostotnog smanjivanja i pojačavanja plavog i crvenog kanala, a najveće kod dvanaestpostotnog smanjivanja i

pojačavanja zelenog kanala, gdje prelaze i postavljenu granicu prihvatljivosti od $\Delta E_{00} = 6$. Također najbliže vrijednosti $\Delta E_{00} = 6$ pokazuju devetpostotne promjene u zelenom kanalu, dok su plavi i crveni kanal zadržali svoje vrijednosti ispod $\Delta E_{00} = 5$ na svim promjenama vrijednosti oslabljivanja i pojačavanja kanala..

Tablica 65 Tablica boja s izračunatim vrijednostima svih varijacija kroz sve kanale ukupno za sve boje

PROMJENA KANALA	TABLICA BOJA			
	MJERENJA			
	ΔE00	ΔL	Δa	Δb
-3R	1.329662	0.355753	1.318709	0.422075
-3G	2.209183	0.897116	-1.9549	1.412388
-3B	1.175149	0.090076	0.561359	-1.48712
-6R	2.442759	0.718797	2.455694	1.360996
-6G	4.075363	1.815355	-3.87196	2.551149
-6B	2.573742	0.100419	1.394299	-3.25869
-9R	3.615287	1.051679	3.864945	1.670261
-9G	5.908067	2.704055	-5.78665	3.877926
-9B	3.451569	0.292583	1.847492	-4.773
-12R	4.965607	1.335335	5.312084	2.151091
-12G	7.320475	3.605938	-7.38133	4.985963
-12B	4.650683	0.386314	2.429032	-6.52176
+3R	1.4567	-0.39761	-1.38576	-0.45776
+3G	2.110927	-0.92302	1.771028	-1.28864
+3B	1.40074	-0.12396	-0.86018	1.779529
+6R	2.58334	-0.75545	-2.70136	-1.16916
+6G	3.931247	-1.79001	3.649447	-2.37331
+6B	2.67724	-0.24048	-1.56524	3.380371
+9R	3.549412	-1.09717	-3.76664	-1.61324
+9G	5.421945	-2.65997	5.079005	-3.57979
+9B	3.557411	-0.3738	-2.20811	4.794149
+12R	4.595086	-1.36486	-4.96125	-2.02603
+12G	6.966375	-3.58177	6.743532	-4.72996
+12B	4.4211	-0.42049	-2.75955	6.268968

Daljnja mjerenja obuhvatila su mjerenje L, a i b vrijednosti polja tablice boja i sve promjene po svim kanalima za oslabljivanje i pojačavanje od tri posto u granicama do +/-12 posto promjene te izračun razlike boja ΔE_{00} u odnosu na standardnu tablicu X-rite boja. Vrijednosti su izračunate korištenjem CIE 2000 kalkulatora za izračun razlike boja na temelju izmjerenih L, a i b vrijednosti. [83] (Slika 86)



Slika 86 Primjer izračuna razlike boja ΔE_{00} za tropostotnu promjenu crvenog kanala kod svijetle boje kože u Lindbloom kalkulatoru boja [83]

Rezultati mjerenja L, a i b vrijednosti te izračunate razlike boja ΔE_{00} su prikazane u tablicama koje prikazuju vrijednosti izmjerene za tamnu i svijetlu boju kože, plavo nebo, lišće, plavi cvijet, osnovne boje aditivne i suptraktivne sinteze te bijelu i crnu boju za crveni kanal oslabljen i pojačan za tri, šest, devet i dvanaest posto, zeleni kanal oslabljen i pojačan za tri, šest, devet i dvanaest posto i plavi kanal oslabljen i pojačan za tri, šest, devet i dvanaest posto. (Tablica 66, Tablica 67, Tablica 68, Tablica 69, Tablica 70, Tablica 71).

Najveće promjene razlike boja ΔE_{00} vidljive su na najvećim promjenama u svakom od kanala, najviše na dvanaestpostotnoj promjeni, zatim na devetpostotnoj promjeni. Tropostotna promjena je dala najmanje promjene razlike boja, kao i šestpostotna promjena. Najveće razlike boja ΔE_{00} prisutne su kod promjena izvedenih u zelenom kanalu, dok su crveni i plavi kanal dali gotovo podjednaki raspon promjena boja. Najmanje odstupanja preko ΔE_{00}=6 dale su promjene unutar plavog kanala zapisa.

*Tablica 66 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan crveni kanal*

Table 2 (8 bit) ColorChecker 2005		0riginal			-3R				-6R				-9R				-12R			
		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	38.00	13.00	16.00	1.60	37.00	11.00	14.00	2.37	37.00	10.00	13.00	3.05	37.00	8.00	13.00	4.99
2	Svijetla koža	65.71	18.13	17.81	66.00	15.00	17.00	2.10	66.00	12.00	16.00	4.33	65.00	10.00	15.00	5.97	65.00	7.00	14.00	8.77
3	Plavo nebo	49.93	-4.88	-21.93	50.00	-6.00	-22.00	0.97	50.00	-7.00	-22.00	1.82	50.00	-7.00	-22.00	2.62	50.00	-8.00	-23.00	2.64
4	Lišće	43.14	-13.10	21.91	43.00	-15.00	22.00	0.75	43.00	-15.00	22.00	1.58	43.00	-17.00	22.00	2.55	42.00	-18.00	21.00	3.55
5	Plavi cvijet	55.11	8.84	-25.40	55.00	9.00	-26.00	0.32	54.00	8.00	-26.00	1.46	54.00	6.00	-26.00	2.87	54.00	5.00	-27.00	4.13
13	Plava	28.78	14.18	-50.30	29.00	14.00	-50.00	0.18	29.00	14.00	-50.00	0.18	29.00	14.00	-51.00	0.46	29.00	14.00	-51.00	0.46
14	Zelena	55.26	-38.34	31.37	55.00	-39.00	31.00	0.43	55.00	-39.00	31.00	0.43	55.00	-40.00	31.00	0.77	55.00	-40.00	31.00	0.77
15	Crvena	42.10	53.38	28.19	42.00	51.00	27.00	0.73	41.00	49.00	25.00	1.85	40.00	47.00	23.00	3.11	39.00	45.00	22.00	4.15
16	Žuta	81.73	4.04	79.82	82.00	3.00	78.00	0.72	81.00	0.00	76.00	2.51	80.00	-4.00	76.00	4.77	80.00	-7.00	75.00	6.54
17	Magenta	51.94	49.99	-14.57	50.00	49.00	-15.00	1.98	49.00	47.00	-16.00	3.22	48.00	45.00	-18.00	4.71	47.00	43.00	-19.00	6.08
18	Cijan	51.04	-28.63	-28.64	51.00	-23.00	-27.00	2.27	51.00	-23.00	-28.00	2.38	52.00	-23.00	-27.00	2.46	52.00	-22.00	-27.00	2.93
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	96.00	-2.00	-1.00	2.50	95.00	-5.00	-2.00	6.16	94.00	-7.00	-3.00	8.41	94.00	-9.00	-4.00	11.00
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	20.00	0.00	0.00	1.01	19.00	0.00	-1.00	1.02	19.00	-2.00	-1.00	2.87	19.00	-3.00	-1.00	4.09

*Tablica 67 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan crveni kanal*

Table 2 (8 bit)		0riginal			3R				6R				9R				12R			
ColorChecker 2005		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	39.00	15.00	17.00	2.00	39.00	17.00	17.00	3.63	40.00	19.00	18.00	4.04	40.00	21.00	19.00	5.04
2	Svijetla koža	65.71	18.13	17.81	68.00	19.00	19.00	1.21	69.00	22.00	20.00	2.99	69.00	24.00	21.00	3.97	70.00	27.00	22.00	5.56
3	Plavo nebo	49.93	-4.88	-21.93	50.00	0.00	-23.00	4.43	50.00	0.00	-22.00	4.62	51.00	2.00	-22.00	6.72	51.00	1.00	-21.00	5.98
4	Lišće	43.14	-13.10	21.91	43.00	-12.00	23.00	1.14	44.00	-11.00	23.00	1.98	44.00	-11.00	24.00	2.31	44.00	-8.00	24.00	4.43
5	Plavi cvijet	55.11	8.84	-25.40	56.00	11.00	-24.00	2.59	56.00	13.00	-24.00	4.03	56.00	14.00	-23.00	5.26	57.00	16.00	-22.00	7.28
13	Plava	28.78	14.18	-50.30	29.00	19.00	-55.00	1.68	29.00	20.00	-55.00	2.24	29.00	20.00	-55.00	2.24	30.00	20.00	-54.00	2.68
14	Zelena	55.26	-38.34	31.37	55.00	-37.00	31.00	0.55	55.00	-37.00	31.00	0.55	55.00	-36.00	31.00	0.92	55.00	-36.00	32.00	1.11
15	Crvena	42.10	53.38	28.19	43.00	55.00	29.00	0.95	44.00	56.00	31.00	2.12	45.00	58.00	32.00	3.16	46.00	60.00	34.00	4.38
16	Žuta	81.73	4.04	79.82	83.00	7.00	81.00	1.90	83.00	10.00	82.00	3.50	84.00	11.00	82.00	4.24	84.00	11.00	82.00	4.24
17	Magenta	51.94	49.99	-14.57	53.00	52.00	-13.00	1.48	54.00	54.00	-12.00	2.75	55.00	55.00	-10.00	4.08	56.00	57.00	-9.00	5.29
18	Cijan	51.04	-28.63	-28.64	51.00	-22.00	-28.00	3.07	51.00	-22.00	-28.00	3.07	51.00	-22.00	-28.00	3.07	51.00	-22.00	-28.00	3.07
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	97.00	3.00	2.00	4.85	98.00	3.00	2.00	4.91	98.00	3.00	2.00	4.91	98.00	3.00	2.00	4.91
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	20.00	1.00	0.00	1.88	20.00	2.00	0.00	3.14	20.00	2.00	1.00	3.52	21.00	3.00	1.00	4.66

*Tablica 68 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan zeleni kanal*

Table 2 (8 bit)		0riginal			-3G				-6G				-9G				-12G			
ColorChecker 2005		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	38.00	15.00	16.00	1.31	37.00	17.00	15.00	2.62	36.00	18.00	14.00	3.76	36.00	20.00	13.00	5.28
2	Svijetla koža	65.71	18.13	17.81	66.00	19.00	16.00	1.60	65.00	21.00	15.00	3.29	64.00	24.00	13.00	6.05	63.00	25.00	12.00	7.25
3	Plavo nebo	49.93	-4.88	-21.93	49.00	1.00	-24.00	5.25	48.00	2.00	-26.00	5.91	47.00	5.00	-28.00	7.92	46.00	6.00	-29.00	8.66
4	Lišće	43.14	-13.10	21.91	42.00	-13.00	21.00	1.14	41.00	-10.00	20.00	2.93	40.00	-9.00	19.00	4.14	39.00	-6.00	18.00	6.66
5	Plavi cvijet	55.11	8.84	-25.40	54.00	13.00	-26.00	3.17	53.00	16.00	-28.00	4.80	52.00	17.00	-30.00	5.35	51.00	18.00	-31.00	6.25
13	Plava	28.78	14.18	-50.30	28.00	15.00	-51.00	0.67	28.00	16.00	-52.00	0.88	27.00	18.00	-53.00	2.07	27.00	19.00	-54.00	2.33
14	Zelena	55.26	-38.34	31.37	54.00	-36.00	29.00	1.60	52.00	-34.00	27.00	3.74	51.00	-33.00	26.00	4.84	49.00	-31.00	24.00	7.10
15	Crvena	42.10	53.38	28.19	42.00	56.00	29.00	0.77	42.00	57.00	28.00	1.31	42.00	58.00	29.00	1.41	41.00	58.00	28.00	1.92
16	Žuta	81.73	4.04	79.82	81.00	9.00	77.00	3.14	79.00	11.00	76.00	4.75	78.00	14.00	75.00	6.76	76.00	17.00	74.00	9.09
17	Magenta	51.94	49.99	-14.57	51.00	54.00	-14.00	1.61	50.00	53.00	-15.00	2.13	50.00	54.00	-16.00	2.30	49.00	55.00	-17.00	3.36
18	Cijan	51.04	-28.63	-28.64	51.00	-21.00	-29.00	3.71	49.00	-19.00	-31.00	5.48	48.00	-17.00	-33.00	7.16	47.00	-15.00	-35.00	8.85
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	94.00	3.00	-3.00	5.35	92.00	7.00	-6.00	10.54	91.00	11.00	-7.00	14.56	89.00	14.00	-11.00	17.92
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	19.00	0.00	0.00	1.39	19.00	1.00	-2.00	2.09	19.00	3.00	-2.00	4.44	18.00	5.00	-3.00	6.98

*Tablica 69 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan zeleni kanal*

Table 2 (8 bit)		0riginal			3G				6G				9G				12G			
ColorChecker 2005		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0.00	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	39.00	13.00	17.00	2.42	40.00	12.00	18.00	3.88	40.00	10.00	19.00	5.74	41.00	9.00	19.00	6.80
2	Svijetla koža	65.71	18.13	17.81	67.00	16.00	19.00	2.29	68.00	13.00	21.00	5.50	69.00	11.00	22.00	7.65	70.00	9.00	24.00	10.18
3	Plavo nebo	49.93	-4.88	-21.93	51.00	-7.00	-20.00	2.35	52.00	-9.00	-19.00	4.41	53.00	-11.00	-17.00	6.71	55.00	-13.00	-15.00	9.48
4	Lišće	43.14	-13.10	21.91	44.00	-15.00	23.00	1.57	45.00	-16.00	25.00	2.86	46.00	-19.00	27.00	4.68	47.00	-20.00	28.00	5.72
5	Plavi cvijet	55.11	8.84	-25.40	56.00	7.00	-23.00	1.49	57.00	4.00	-21.00	3.71	58.00	2.00	-20.00	5.58	59.00	1.00	-19.00	6.83
13	Plava	28.78	14.18	-50.30	30.00	13.00	-49.00	1.02	30.00	11.00	-48.00	1.63	31.00	10.00	-47.00	2.40	31.00	9.00	-46.00	2.66
14	Zelena	55.26	-38.34	31.37	56.00	-40.00	34.00	1.23	58.00	-42.00	36.00	3.11	59.00	-44.00	37.00	4.16	61.00	-45.00	40.00	6.12
15	Crvena	42.10	53.38	28.19	42.00	56.00	29.00	0.77	42.00	55.00	29.00	0.49	42.00	55.00	29.00	0.49	43.00	55.00	30.00	1.12
16	Žuta	81.73	4.04	79.82	84.00	3.00	79.00	1.64	85.00	0.00	81.00	3.21	87.00	-3.00	82.00	5.36	88.00	-6.00	83.00	6.70
17	Magenta	51.94	49.99	-14.57	52.00	49.00	-14.00	0.36	53.00	48.00	-13.00	1.34	53.00	46.00	-13.00	1.69	54.00	45.00	-12.00	2.69
18	Cijan	51.04	-28.63	-28.64	52.00	-23.00	-26.00	2.17	53.00	-25.00	-24.00	2.40	54.00	-27.00	-22.00	4.14	56.00	-29.00	-20.00	6.42
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	99.00	-3.00	4.00	4.35	99.00	-4.00	4.00	5.30	99.00	-4.00	4.00	5.30	99.00	-4.00	4.00	5.30
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	20.00	0.00	-1.00	0.34	21.00	-2.00	0.00	2.88	21.00	-2.00	1.00	3.32	22.00	-3.00	2.00	4.95

*Tablica 70 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan plavi kanal*

Table 2 (8 bit)		Original			-3B				-6B				-9B				-12B			
ColorChecker 2005		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	38.00	14.00	18.00	2.51	38.00	14.00	18.00	2.51	38.00	13.00	19.00	3.54	38.00	14.00	20.00	3.77
2	Svijetla koža	65.71	18.13	17.81	67.00	16.00	19.00	2.29	67.00	15.00	20.00	3.40	67.00	16.00	24.00	4.90	67.00	15.00	26.00	6.48
3	Plavo nebo	49.93	-4.88	-21.93	50.00	-2.00	-20.00	3.02	50.00	-4.00	-17.00	2.60	49.00	-5.00	-15.00	3.74	49.00	-5.00	-13.00	4.94
4	Lišće	43.14	-13.10	21.91	43.00	-13.00	23.00	0.62	43.00	-13.00	24.00	1.14	43.00	-13.00	25.00	1.65	43.00	-13.00	26.00	2.14
5	Plavi cvijet	55.11	8.84	-25.40	55.00	10.00	-23.00	2.32	55.00	9.00	-20.00	3.64	55.00	7.00	-16.00	5.45	54.00	7.00	-14.00	6.92
13	Plava	28.78	14.18	-50.30	29.00	12.00	-48.00	0.76	28.00	11.00	-45.00	1.30	28.00	10.00	-43.00	1.72	28.00	8.00	-41.00	2.13
14	Zelena	55.26	-38.34	31.37	55.00	-39.00	34.00	2.84	55.00	-39.00	35.00	3.01	55.00	-40.00	36.00	3.17	55.00	-40.00	37.00	3.40
15	Crvena	42.10	53.38	28.19	42.00	56.00	30.00	0.87	42.00	56.00	31.00	1.19	42.00	56.00	32.00	1.60	42.00	56.00	33.00	2.05
16	Žuta	81.73	4.04	79.82	82.00	5.00	78.00	0.75	83.00	5.00	79.00	1.05	83.00	5.00	79.00	1.60	82.00	5.00	79.00	2.05
17	Magenta	51.94	49.99	-14.57	51.00	51.00	-11.00	1.97	51.00	50.00	-9.00	2.75	50.00	49.00	-6.00	4.10	50.00	49.00	-3.00	5.78
18	Cijan	51.04	-28.63	-28.64	52.00	-24.00	-24.00	2.64	52.00	-26.00	-22.00	3.08	51.00	-27.00	-19.00	4.60	51.00	-28.00	-16.00	6.31
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	97.00	-1.00	4.00	2.62	97.00	-2.00	8.00	5.90	96.00	-3.00	12.00	8.71	96.00	-3.00	15.00	10.38
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	20.00	-1.00	2.00	3.18	20.00	0.00	1.00	1.97	20.00	-1.00	2.00	3.18	20.00	-1.00	3.00	4.01

*Tablica 71 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan plavi kanal*

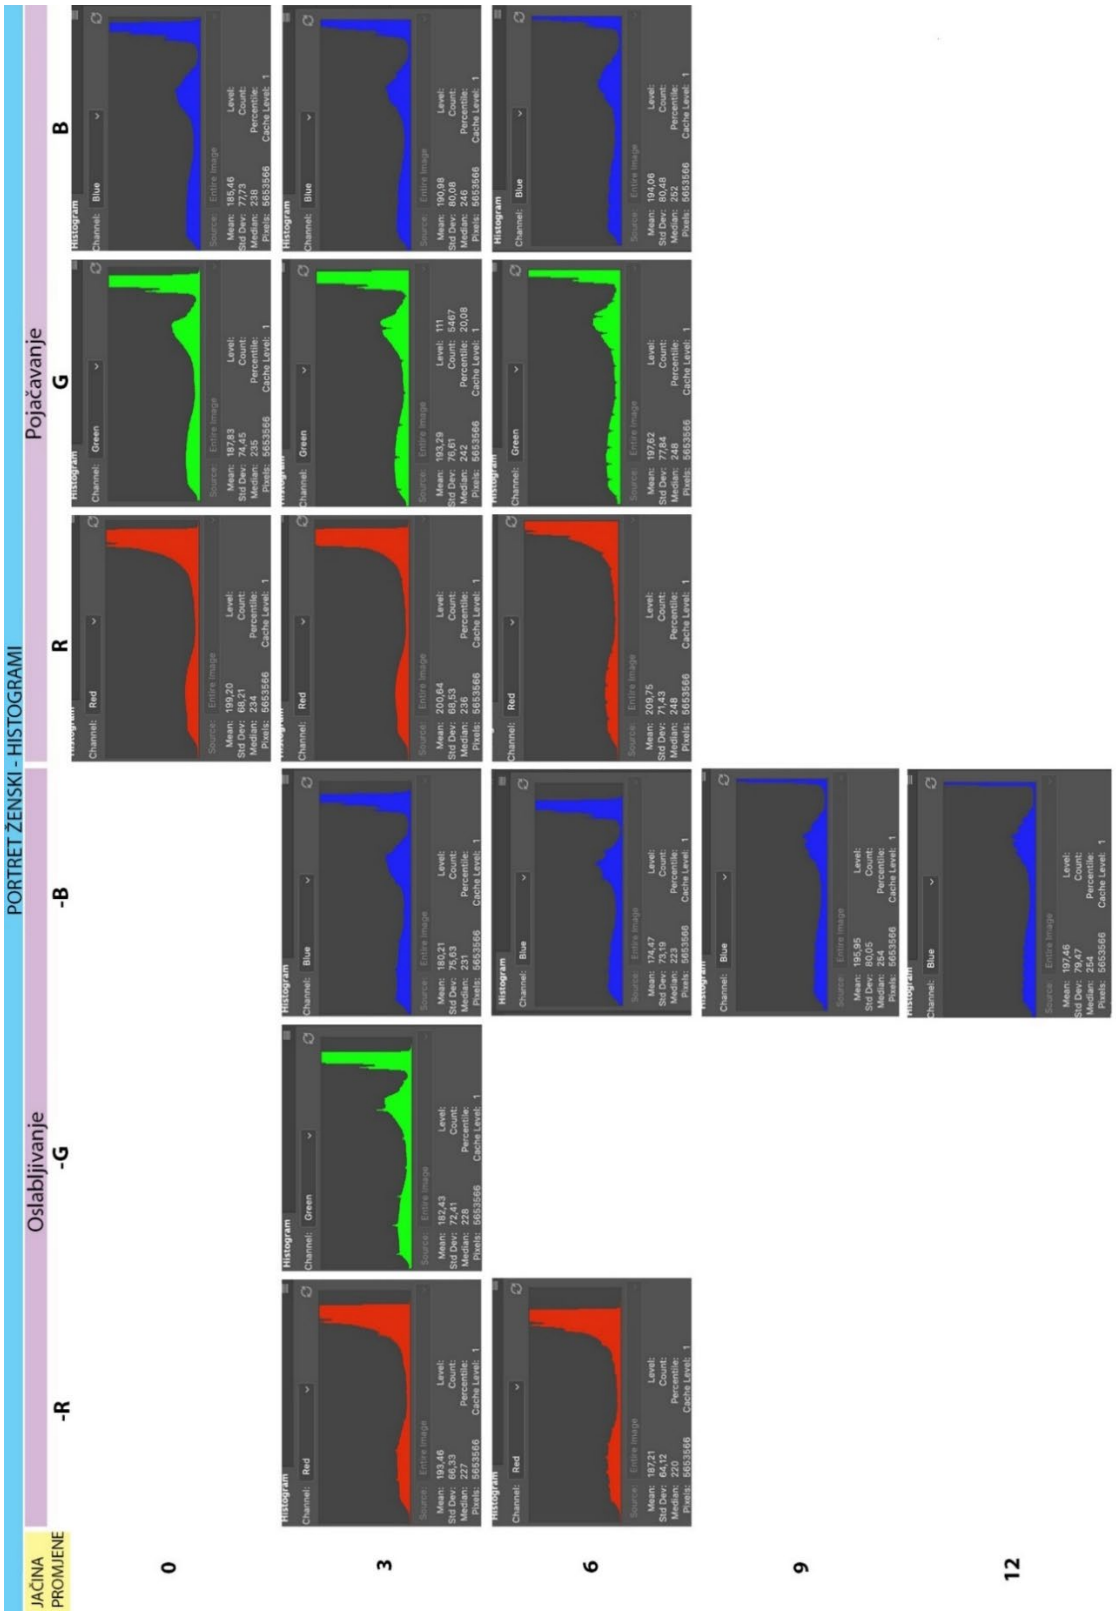
Table 2 (8 bit)		0riginal			3B				6B				9B				12B			
ColorChecker 2005		L*a*b* (CIE D50)			L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)				L*a*b* (CIE D50)			
Br.	Naziv boje	L*	a*	b*	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE	L*	a*	b*	ΔE
0	illuminant	100	0	0	100	0	0		100	0	0		100	0	0		100	0	0	
1	Tamna koža	37.99	13.56	14.06	38.00	15.00	14.00	1.17	39.00	15.00	13.00	1.84	38.00	15.00	12.00	2.21	38.00	15.00	11.00	2.86
2	Svijetla koža	65.71	18.13	17.81	67.00	16.00	16.00	1.76	67.00	17.00	14.00	2.54	67.00	18.00	11.00	4.77	67.00	18.00	9.00	6.18
3	Plavo nebo	49.93	-4.88	-21.93	50.00	-4.00	-24.00	1.09	50.00	-3.00	-27.00	2.27	51.00	-2.00	-29.00	3.18	51.00	-1.00	-32.00	3.90
4	Lišće	43.14	-13.10	21.91	43.00	-13.00	21.00	0.49	43.00	-13.00	20.00	1.03	43.00	-13.00	19.00	1.59	43.00	-12.00	18.00	2.05
5	Plavi cvijet	55.11	8.84	-25.40	55.00	12.00	-28.00	1.72	55.00	12.00	-30.00	1.97	56.00	13.00	-33.00	3.20	56.00	15.00	-36.00	4.23
13	Plava	28.78	14.18	-50.30	30.00	21.00	-57.00	2.53	30.00	22.00	-59.00	2.71	30.00	24.00	-61.00	3.34	30.00	25.00	-63.00	3.56
14	Zelena	55.26	-38.34	31.37	55.00	-38.00	30.00	0.60	55.00	-38.00	29.00	1.01	55.00	-37.00	28.00	1.37	55.00	-37.00	27.00	1.79
15	Crvena	42.10	53.38	28.19	42.00	57.00	27.00	1.66	42.00	57.00	27.00	1.66	42.00	57.00	27.00	1.66	42.00	56.00	25.82	1.79
16	Žuta	81.73	4.04	79.82	82.00	6.00	78.00	1.28	82.00	6.00	78.00	1.28	82.00	6.00	78.00	1.28	82.00	6.00	78.00	1.28
17	Magenta	51.94	49.99	-14.57	51.00	51.00	-15.00	0.99	51.00	52.00	-19.00	2.13	51.00	52.00	-21.00	2.92	52.00	53.00	-29.00	6.06
18	Cijan	51.04	-28.63	-28.64	51.00	-20.00	-31.00	4.58	51.00	-19.00	-33.00	5.50	52.00	-17.00	-36.00	7.18	52.00	-15.00	-39.00	8.73
19	Bijela 9.5 (.05 D)	96.54	-0.43	1.19	97.00	1.00	-2.00	3.75	97.00	2.00	-4.00	5.94	97.00	2.00	-4.00	5.94	97.00	2.00	-4.00	5.94
24	Crna 2 (1.5 D)	20.46	-0.08	-0.97	20.00	0.00	-1.00	0.34	20.00	1.00	-3.00	2.42	20.00	1.00	-3.00	2.42	20.00	2.00	-4.00	3.91

Tablica boja s oslabljenim promjenama u crvenom kanalu prelazi granicu ΔE_{00}=6 na području bijele boje od šestpostotnog oslabljivanja dalje te u dvanaestpostotnom oslabljivanju za boju svijetle kože, žutu i magentu. Kod devetpostotnog pojačavanja granicu u crvenom kanalu prelazi boja plavog neba, samo za to pojačanje te na dvanaestpostotnom pojačanju boja plavog cvijeta. Ukupno za promjenu unutar crvenog kanala postoji deset prekoračenja granice ΔE_{00}=6. Šest prekoračenja kod oslabljivanja (četiri kod dvanaestpostotne promjene), a kod pojačavanja kanala dva prekoračenja (jedan kod dvanaestpostotne promjene). (Tablica 66, Tablica 67)
Tablica boja s oslabljenim promjenama u zelenom kanalu na šestpostotnoj promjeni pokazuje prelazak granice ΔE_{00}=6 na bijeloj boji, prelazak granice ΔE_{00}=6 na devetpostotnoj promjeni za biju, cijan, žutu, plavo nebo i svijetlu boju kože te na dvanaestpostotnoj promjeni za bijelu, cijan, žutu, zelenu, plavi cvijet, lišće, plavo nebo i svijetlu boju kože. U slučaju pojačavanja zelenog kanala granicu od ΔE_{00}=6 prelaze boja plavog neba i svijetla boja kože, a na dvanaestpostotnom pojačanju boje cijan, žuta, zelena, boja plavog cvijeta, boja plavog neba i svijetla i tamna boja kože. Ukupno za promjenu unutar zelenog kanala postoji dvadeset i šest prekoračenja granice ΔE_{00}=6. U slučaju oslabljivanja radi se o petnaest prekoračenja granice (devet kod dvanaestpostotne promjene), a kod pojačavanja devet prekoračenja granice (od čega sedam u dvanaestpostotnoj promjeni). (Tablica 68, Tablica 69)
Tablica boja sa oslabljivanim promjenama u plavom kanalu prelazak granice od ΔE_{00}=6 prelazi na devetpostotnoj promjeni za bijelu boju, te na dvanaestpostotnim promjenama za bijelu boju, cijan, boju plavog cvijeta i svijetlu boju kože. U slučaju pojačavanja kod plavog kanala granicu od ΔE_{00}=6 na devetpostotnom pojačanju prelazi cijan, zatim na dvanaestpostotnom cijan, magenta i svijetla boja kože. Ukupno za promjenu unutar plavog kanala zabilježeno je devet prekoračenja granice od ΔE_{00}=6. Kod oslabljivanja u pet prekoračenja (od čega četiri za dvanaestpostotnu promjenu), a kod pojačavanja za četiri prekoračenja (od čega tri za dvanaestpostotnu promjenu). (Tablica 70, Tablica 71)

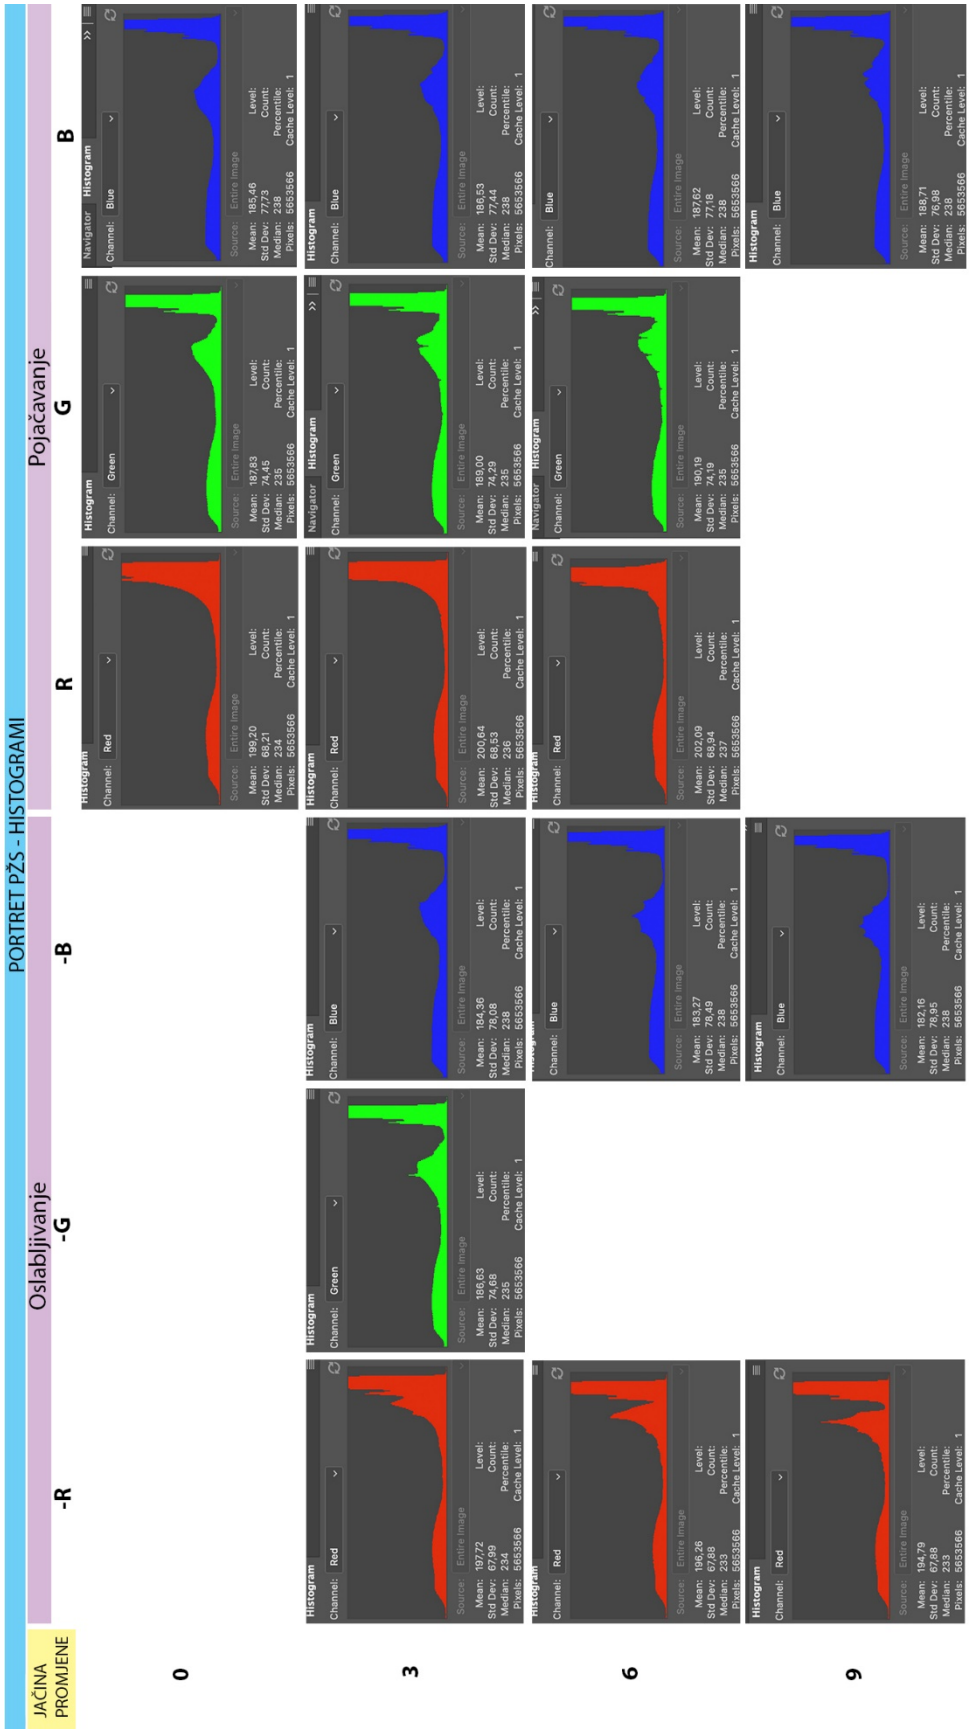
4.3.3. Histogrami fotografskih slika

Zastupljenost boje kanala (plave, zelene i crvene) se mijenja sa svakom promjenom pozitivnom ili negativnom što je vidljivo iz brojčanih vrijednosti svakog histograma. (Slika 87, Slika 88, Slika 89, Slika 90, Slika 91, Slika 92, Slika 93, Slika 94, Slika 95, Slika 96, Slika 97, Slika 98, Slika 99). Međutim, iako je vizualna analiza histograma sukladna s rezultatima prethodnih istraživanja, usporedbe pojedinih histograma uz promjene pojedinih kanala zapisa ne pokazuju signifikantne promjene. Pri tome treba naglasiti da se pri analizi fotografske slike preko

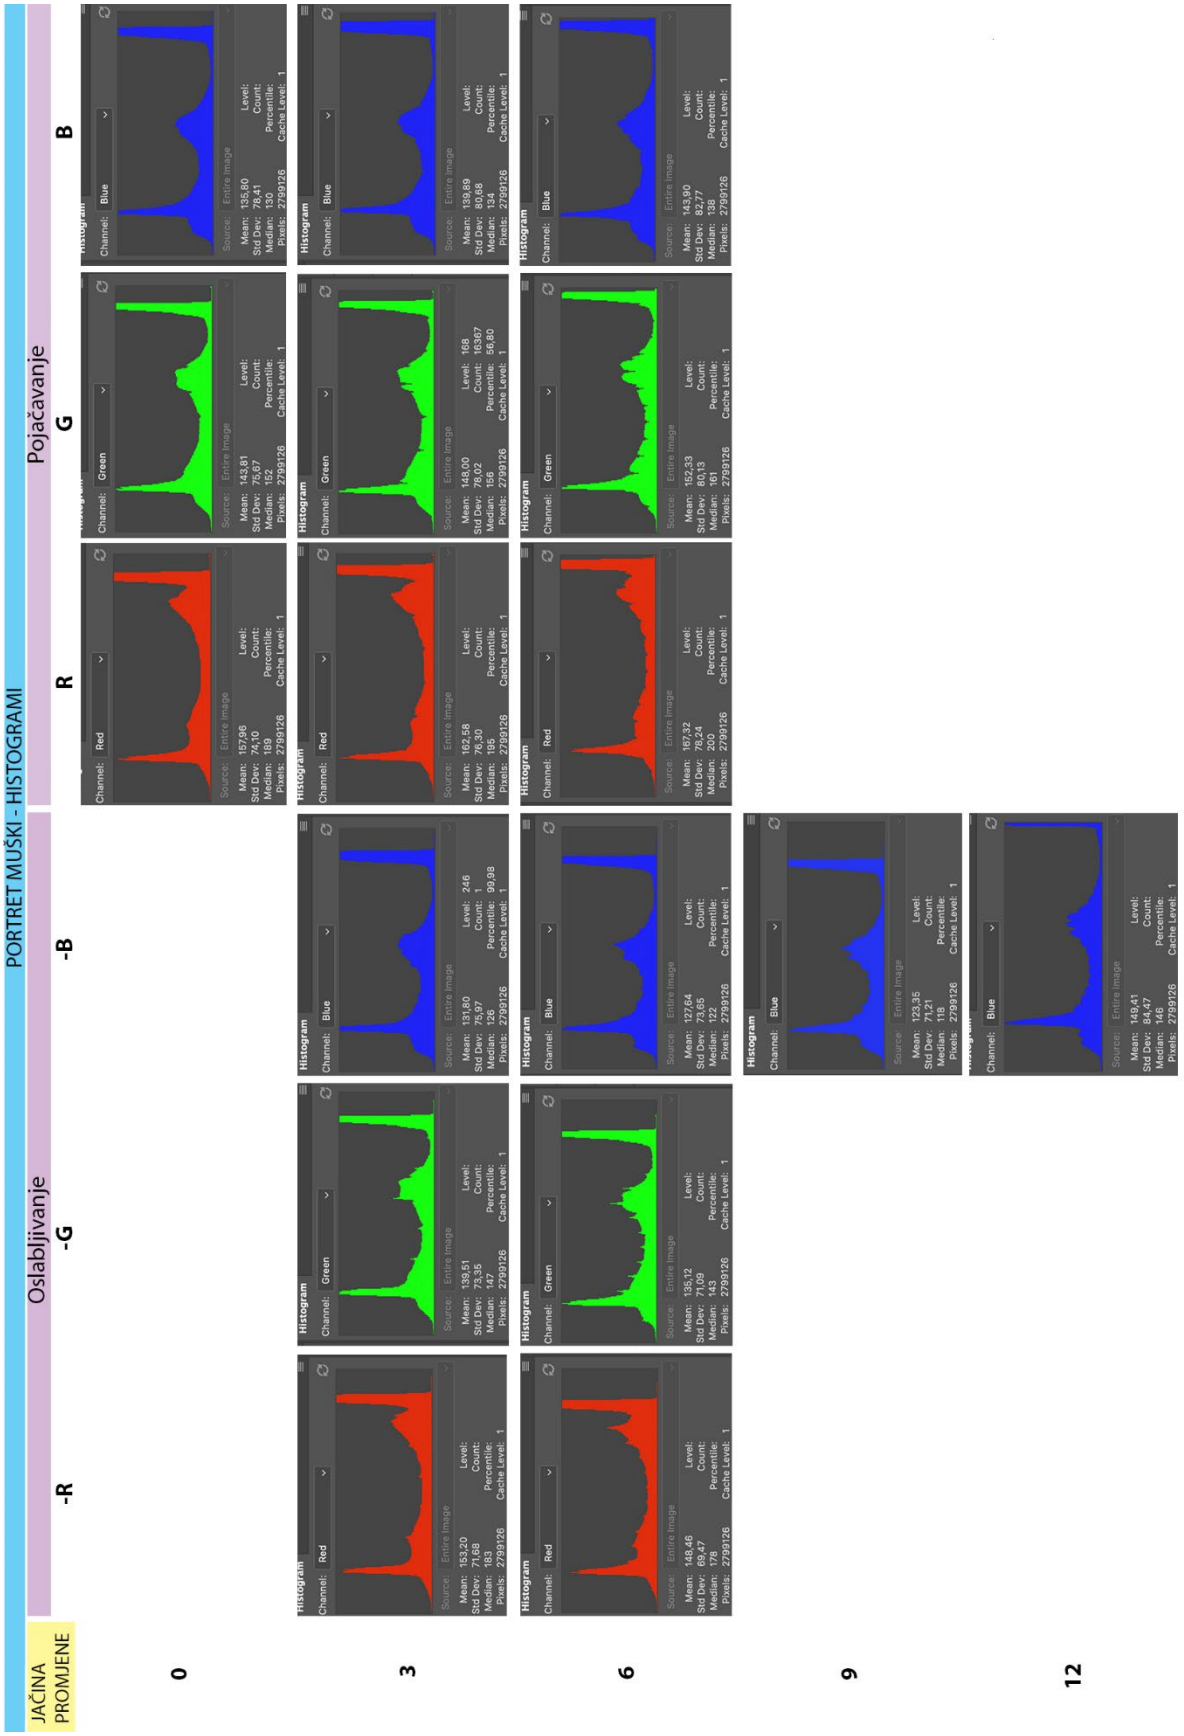
histograma upravo primarno koriste vizualne usporedbe histograma te time procjene fotografske slike.



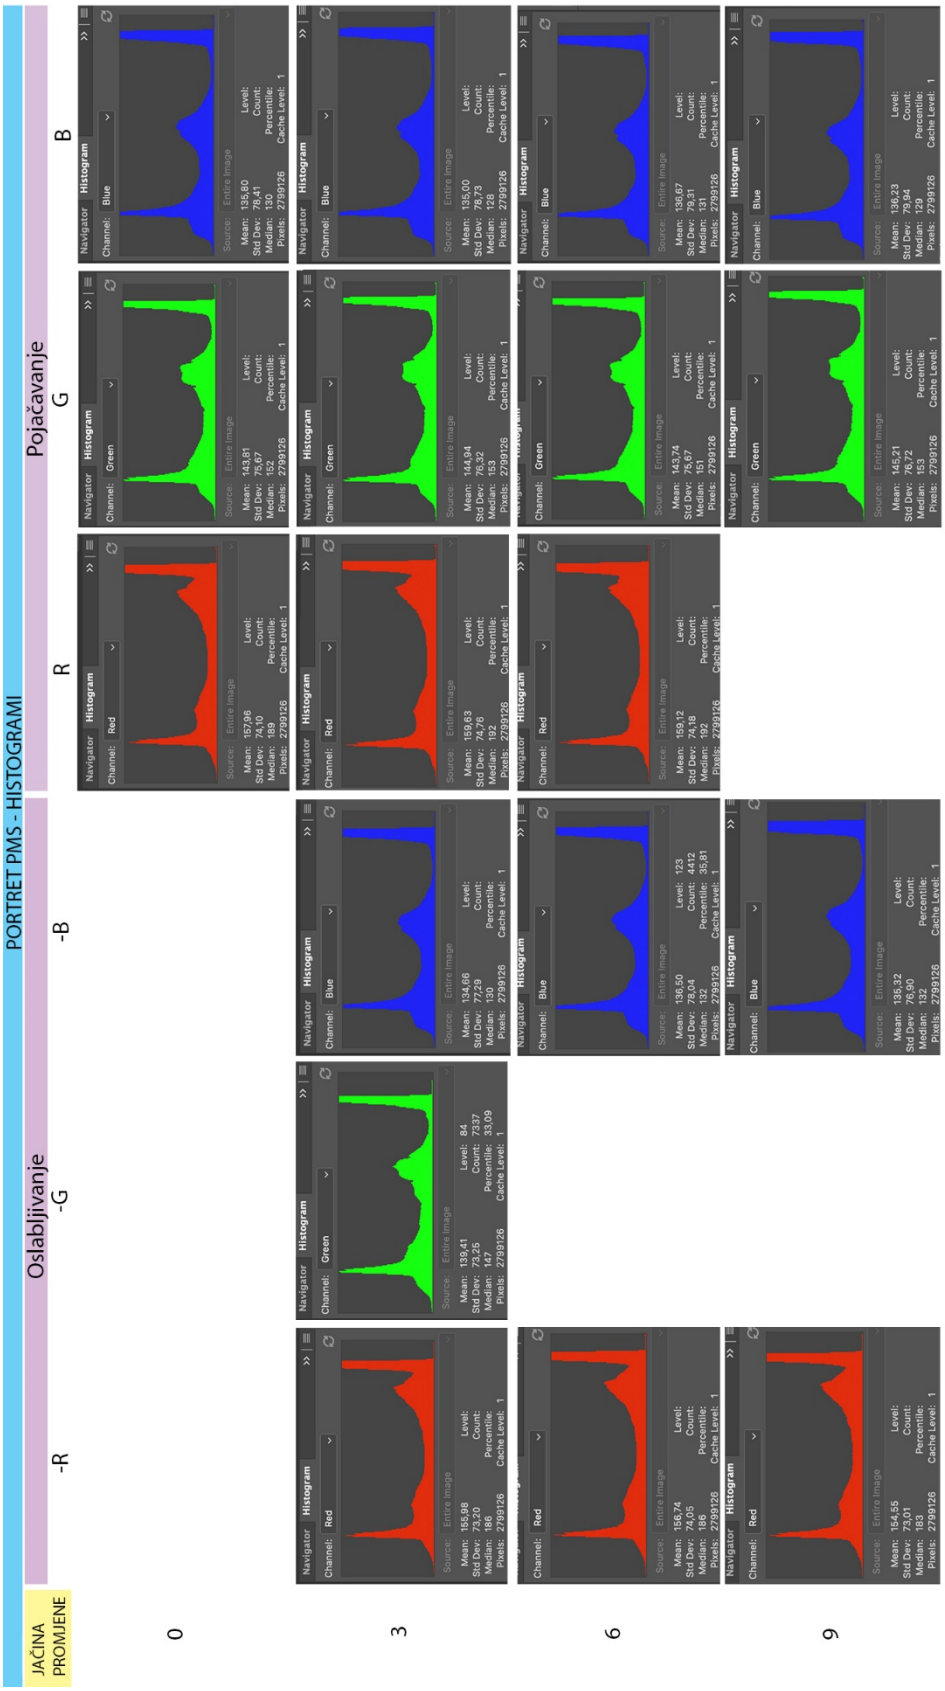
Slika 87 Histogrami kod fotografije ženskog portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



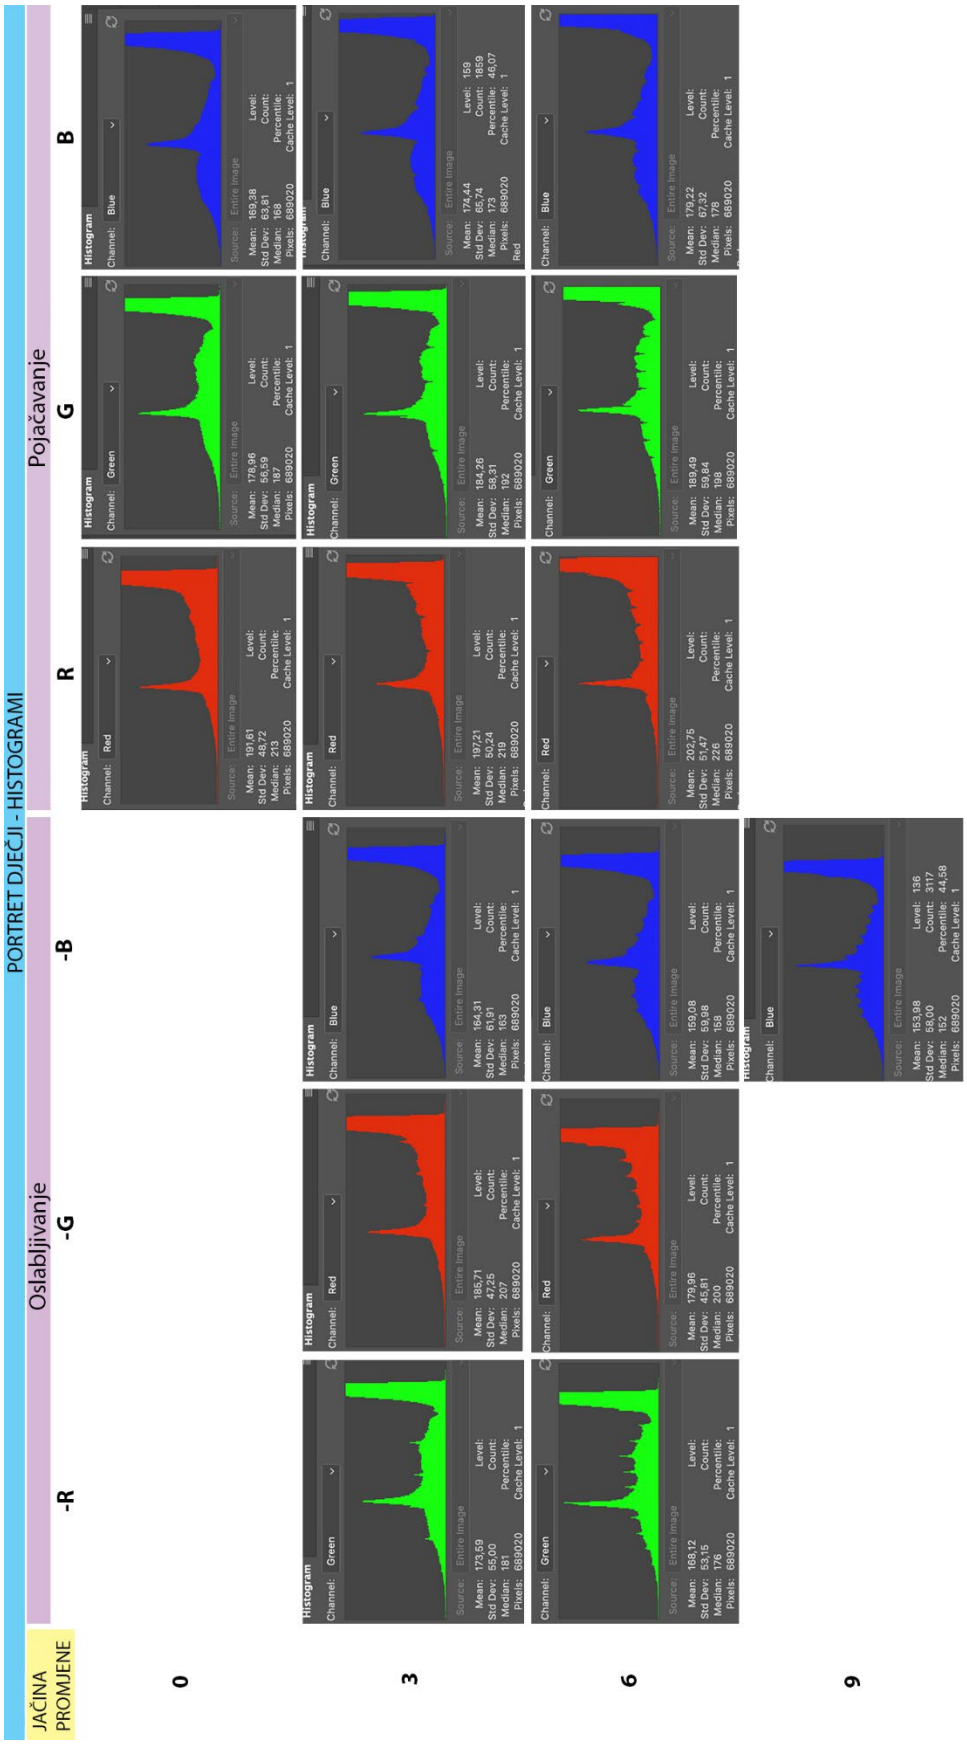
Slika 88 Histogrami kod fotografije ženskog portreta sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



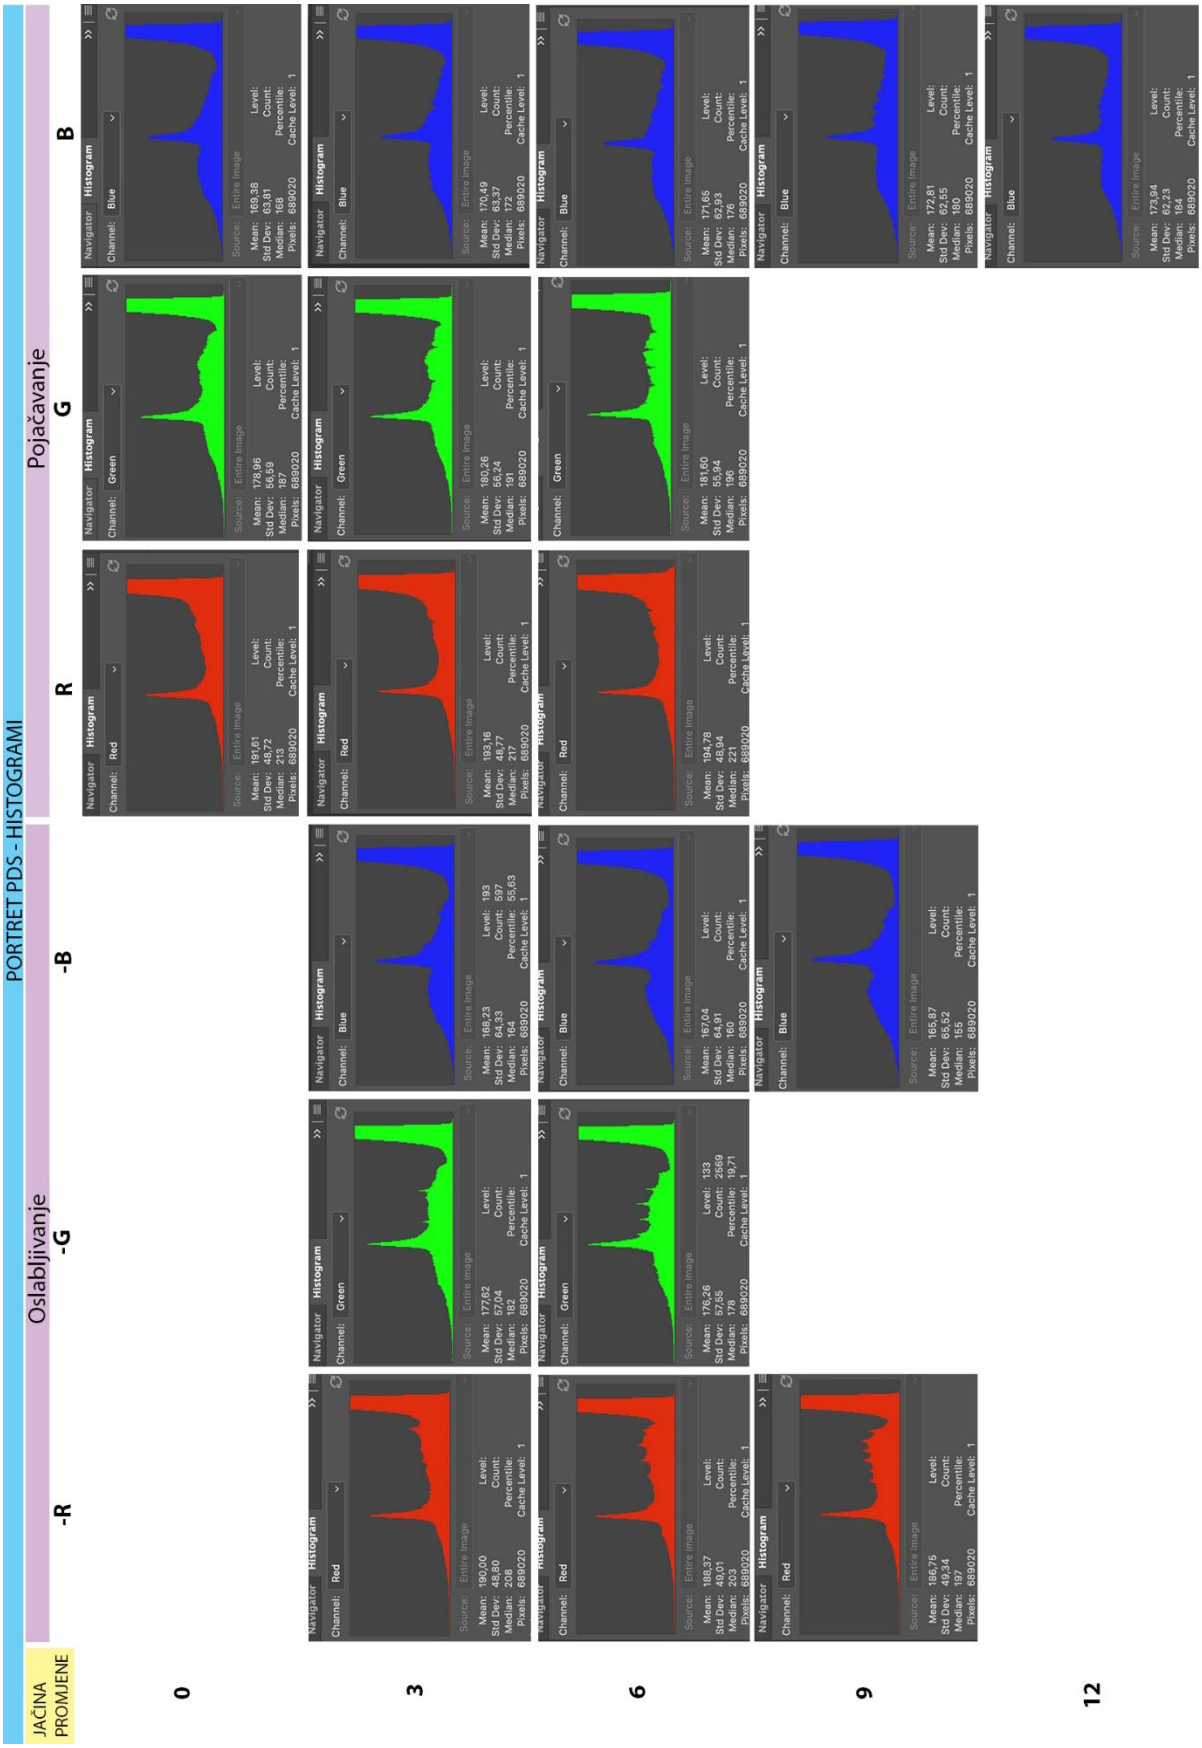
Slika 89 Histogrami kod fotografije muškog portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



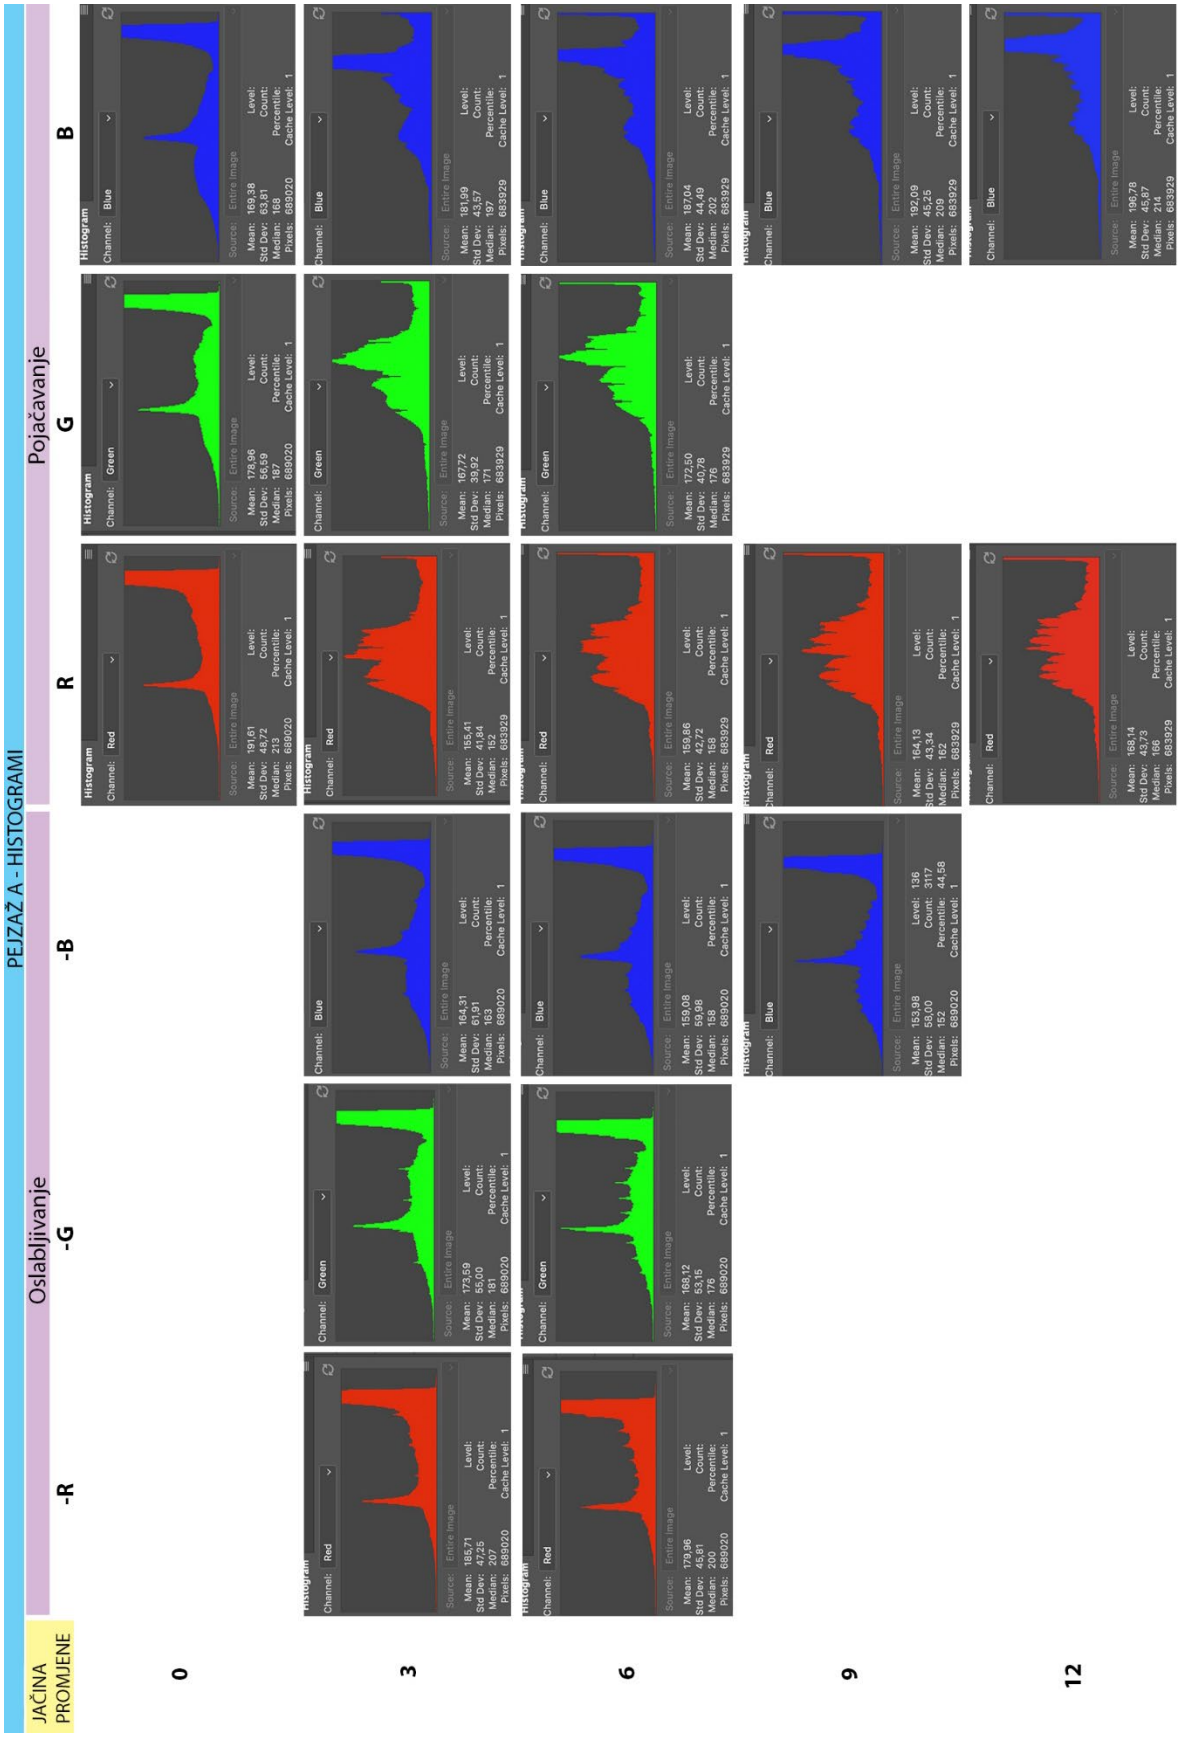
Slika 90 Histogrami kod fotografije muškog portreta sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



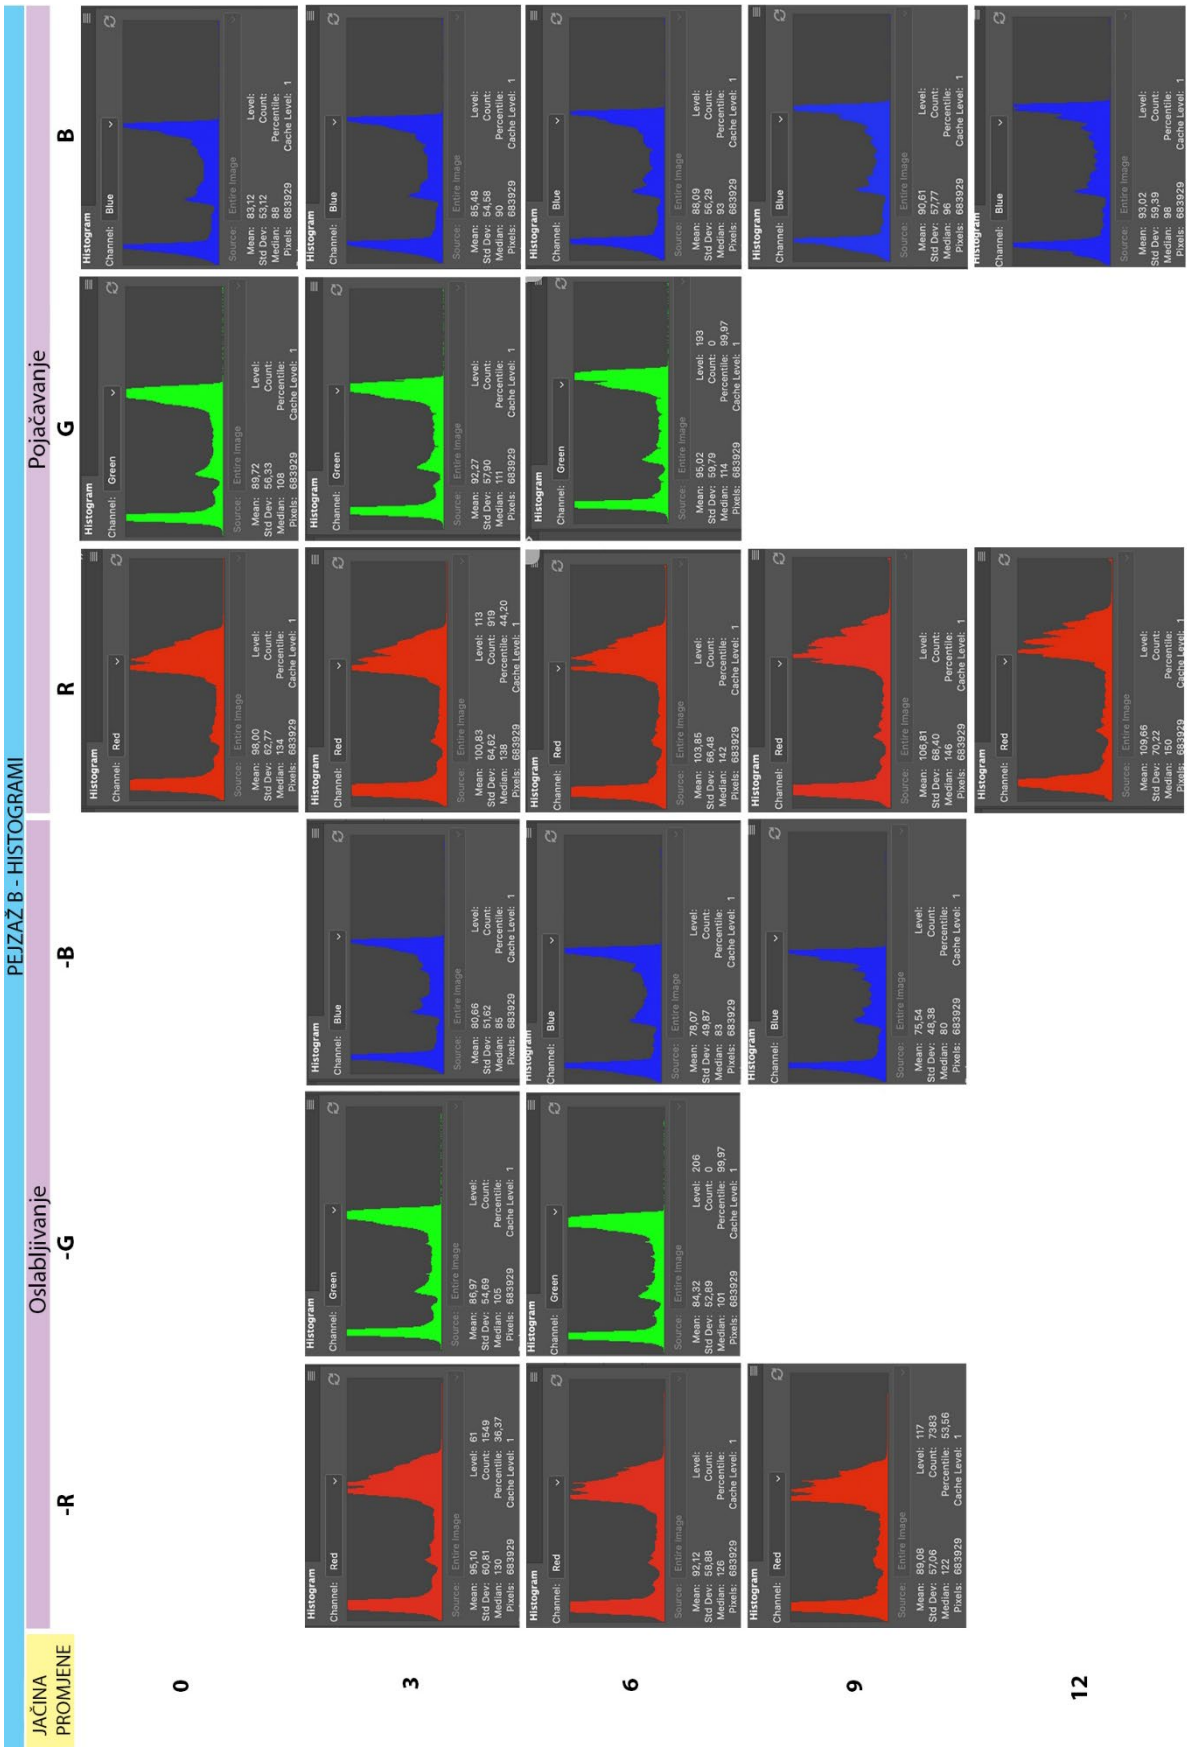
Slika 91 Histogrami kod fotografije dječjeg portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



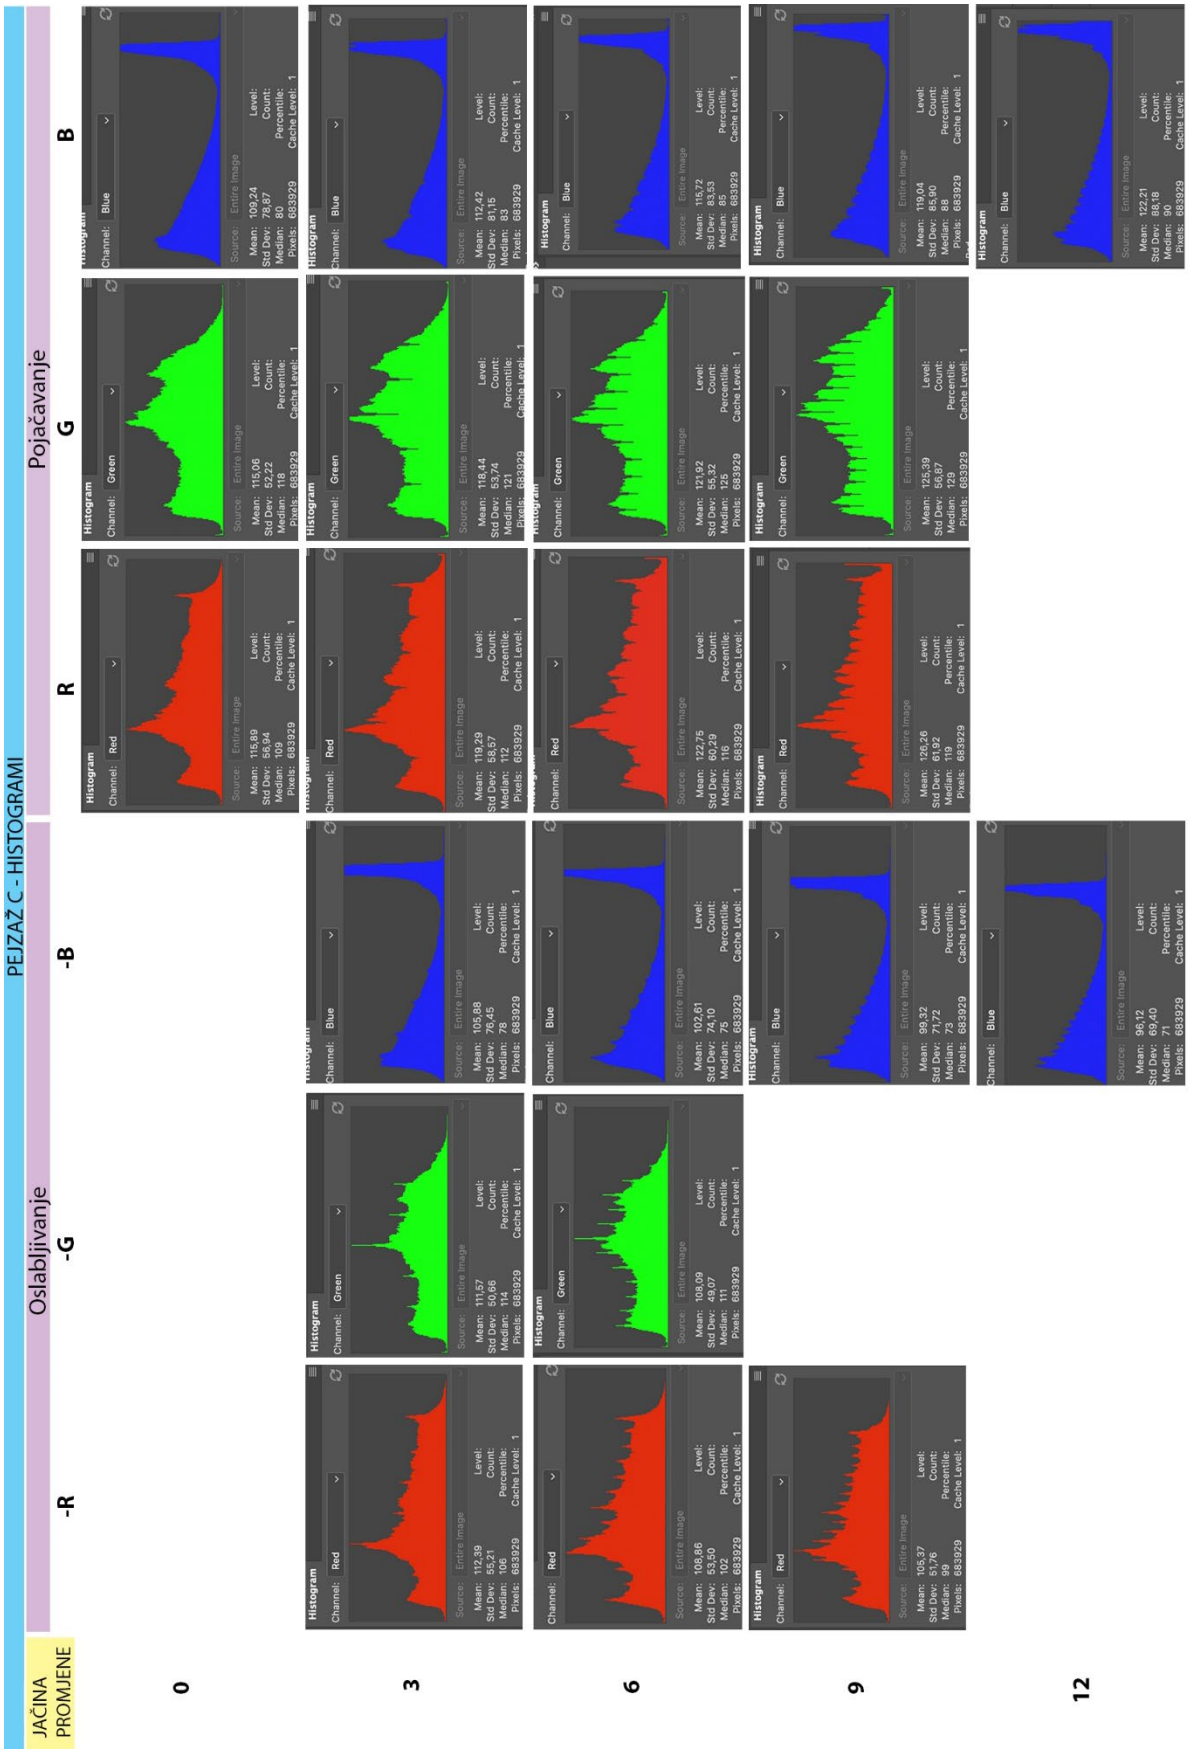
Slika 92 Histogrami kod fotografije dječjeg portreta sa selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



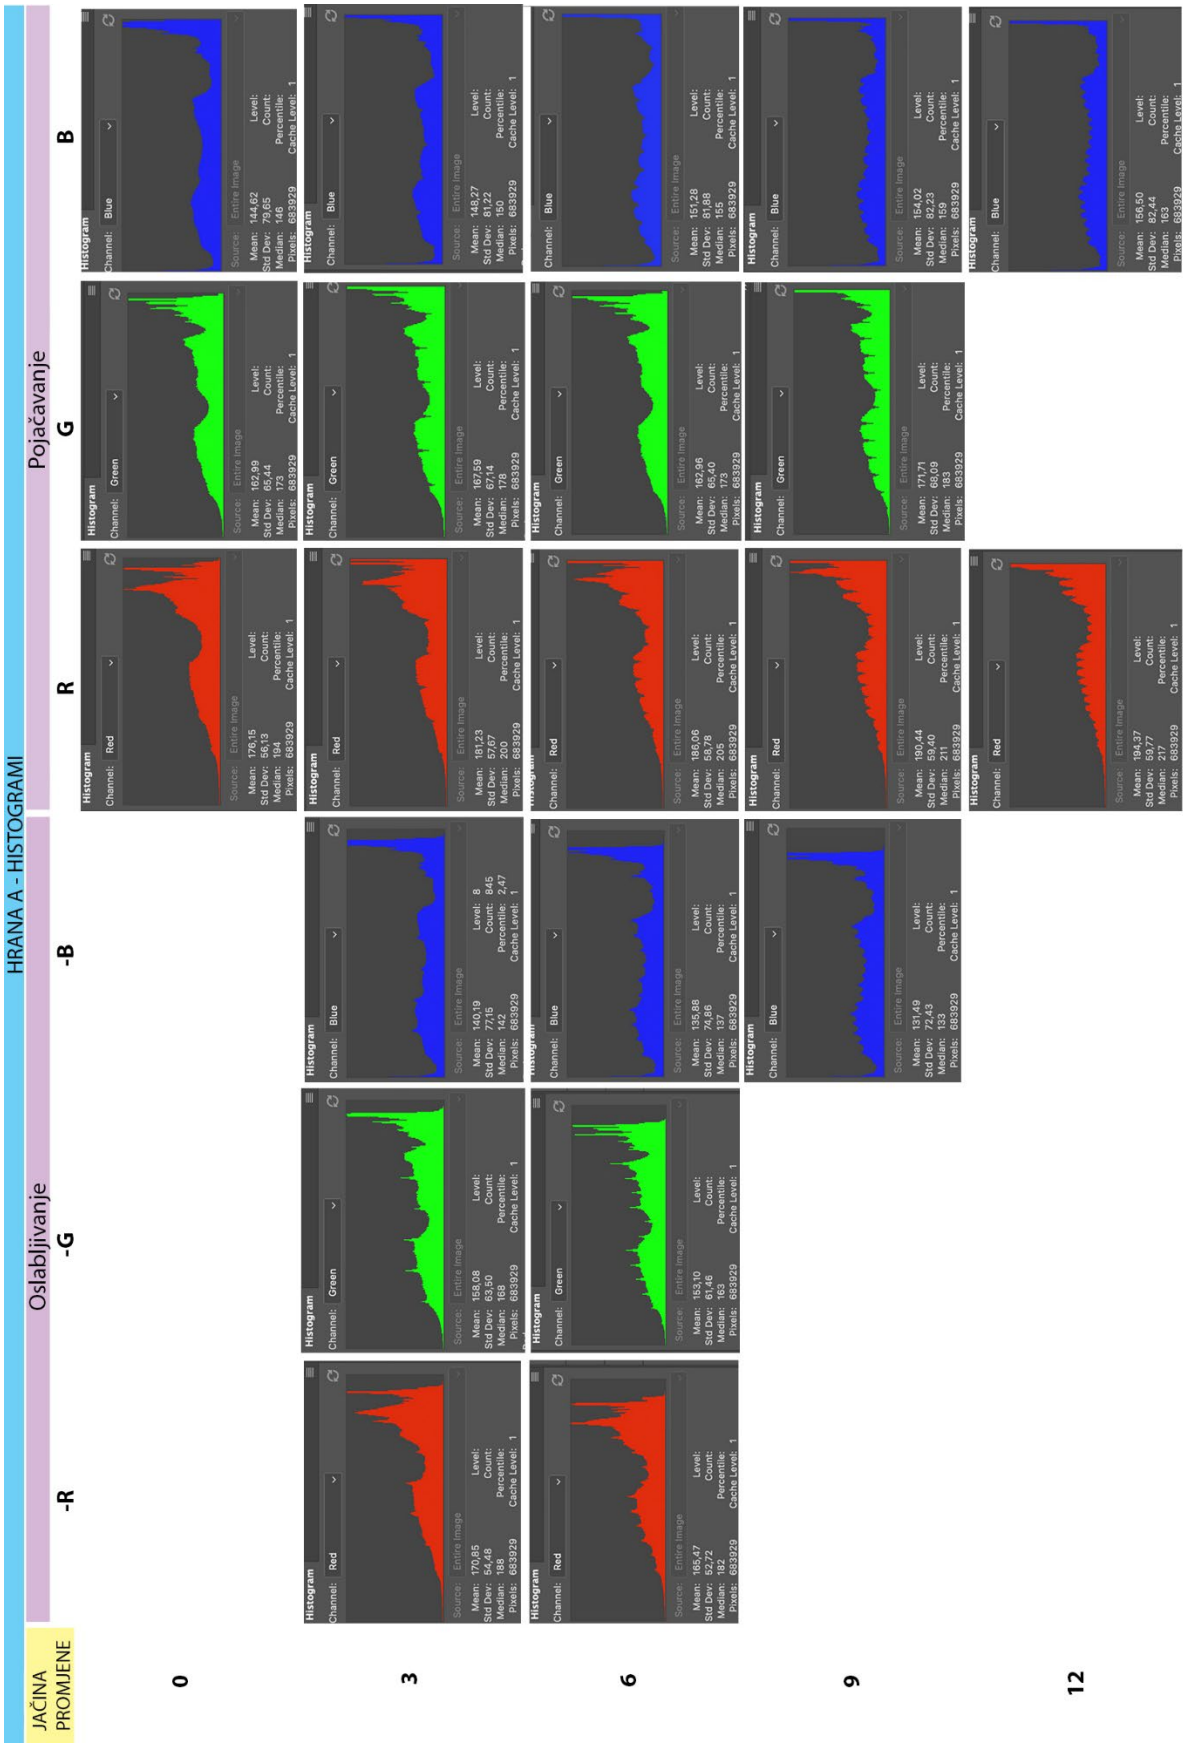
Slika 93 Histogrami kod fotografije pejzaža A bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



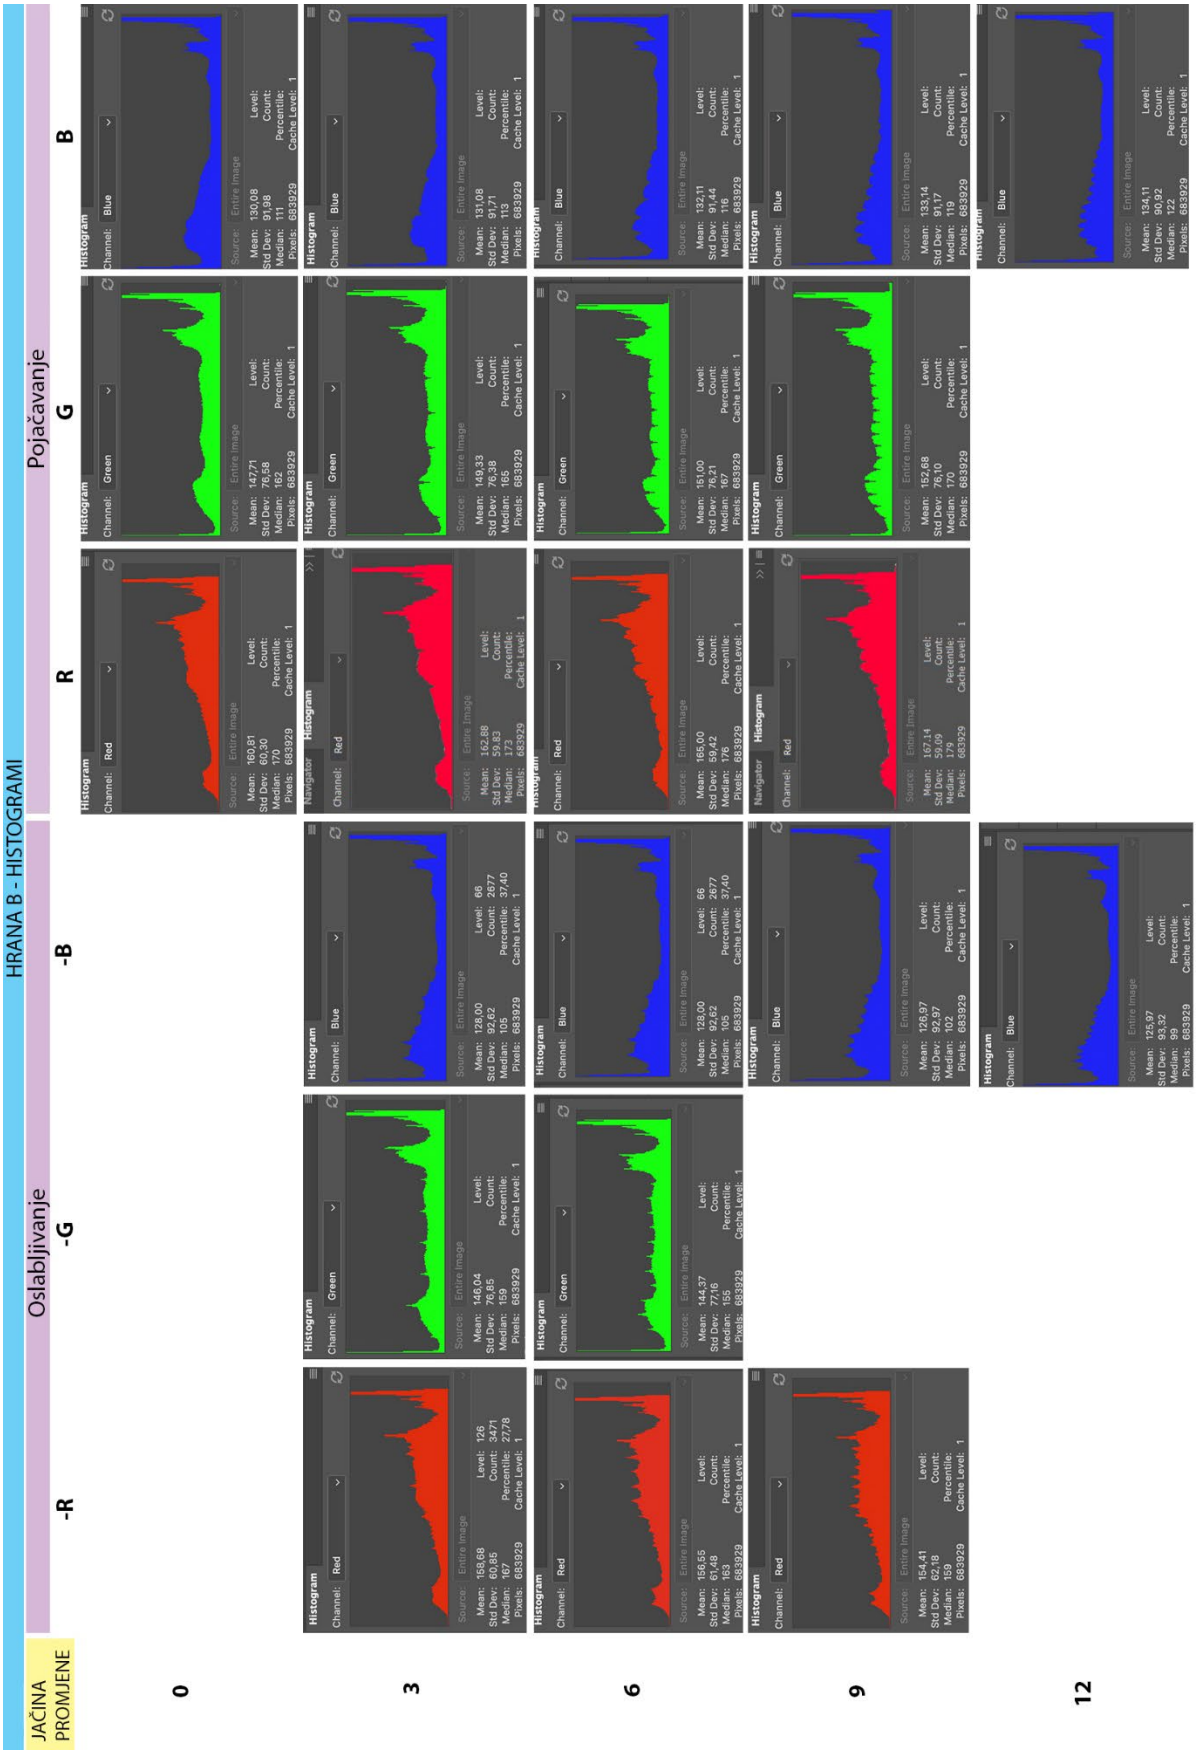
Slika 94 Histogrami kod fotografije pejzaža B bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



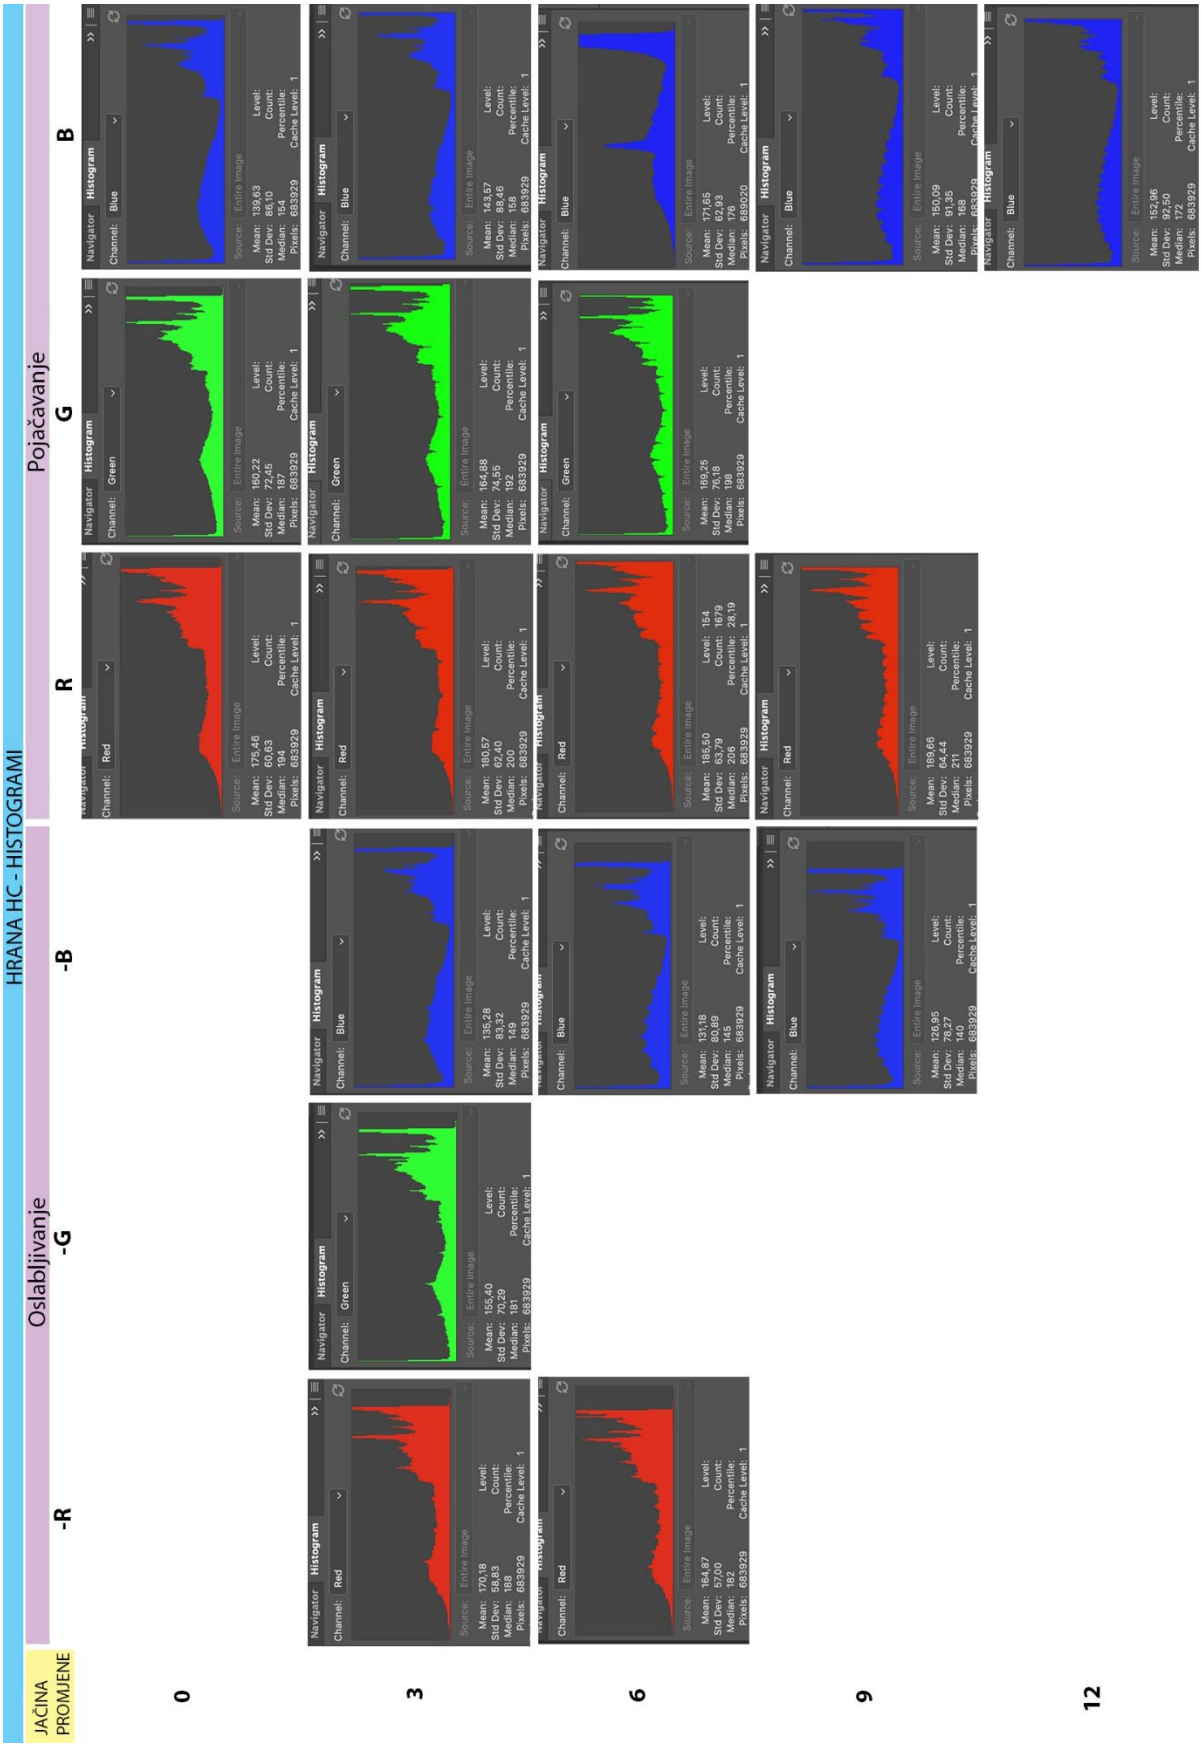
Slika 95 Histogrami kod fotografije pejzaža C bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



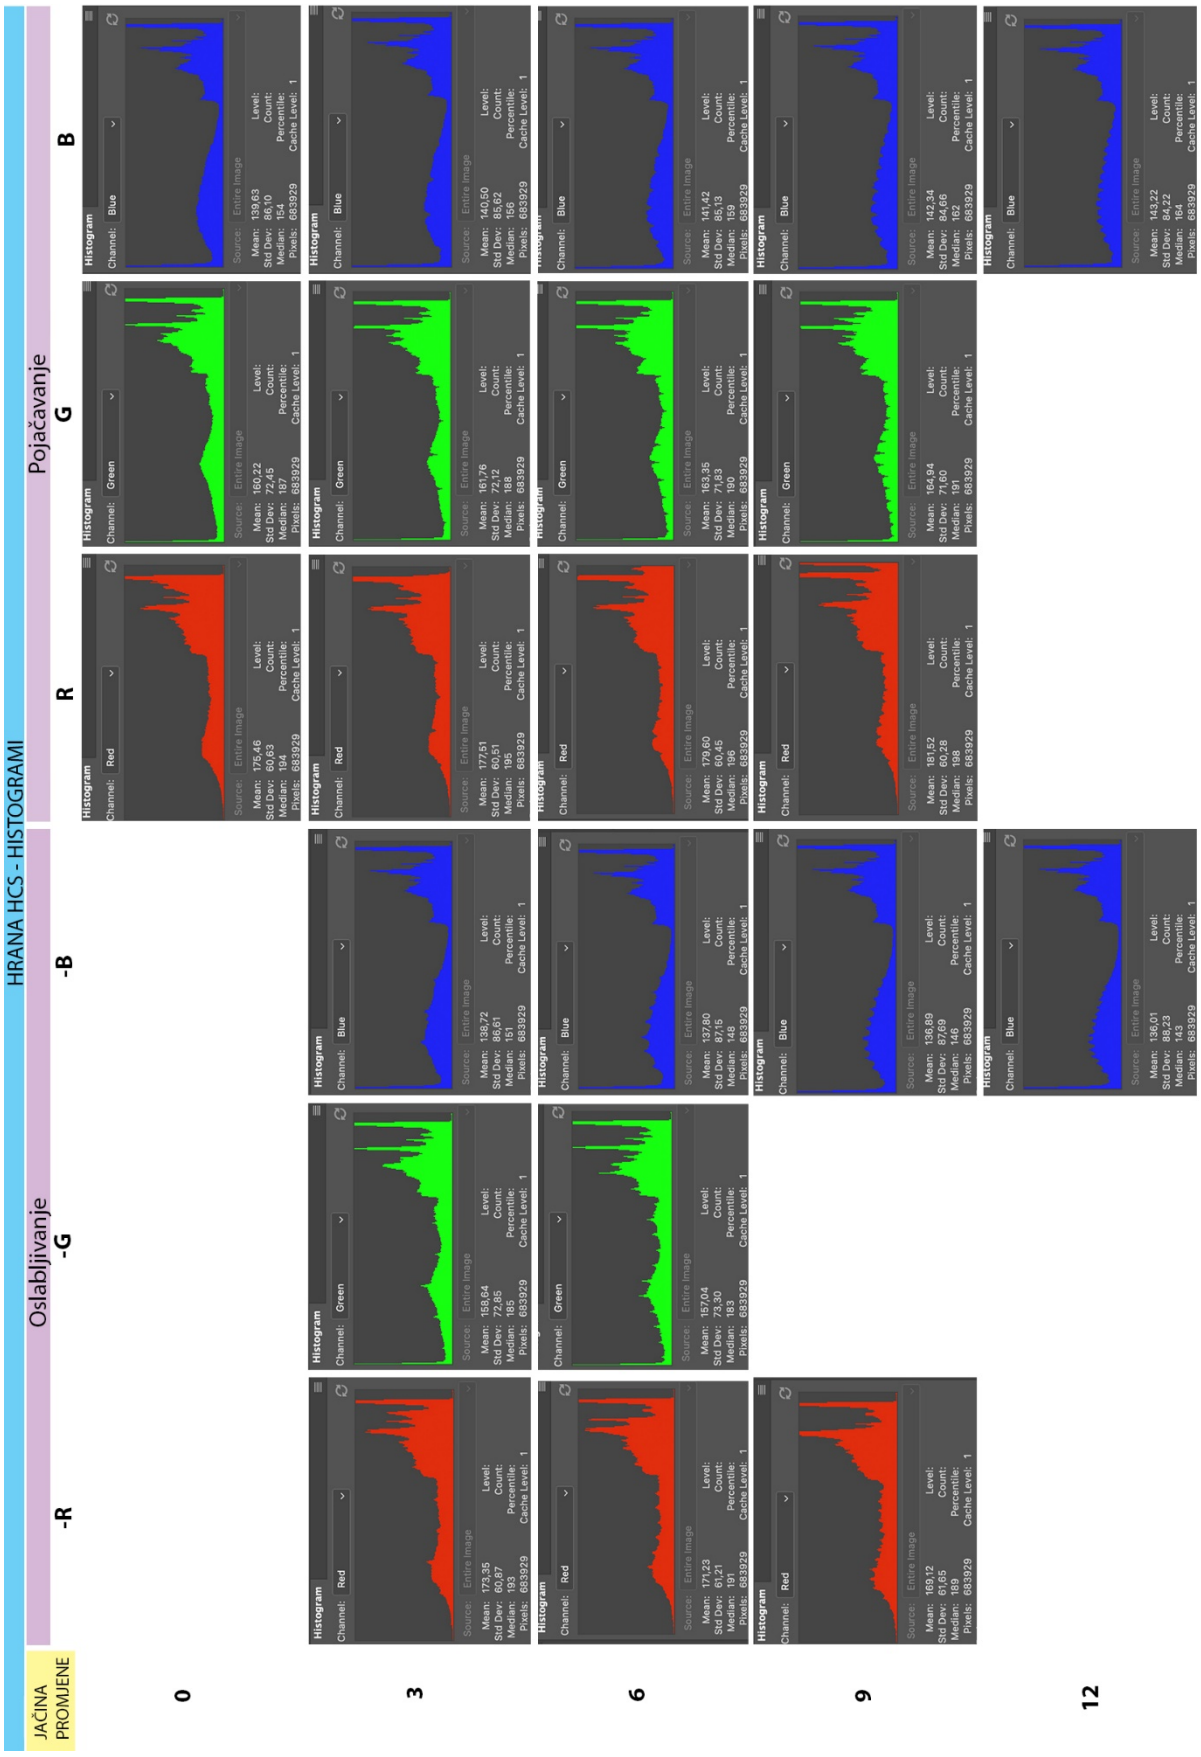
Slika 96 Histogrami kod fotografije hrane A bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



Slika 97 Histogrami kod fotografije hrane B sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



Slika 98 Histogrami kod fotografije hrane C bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %



Slika 99 Histogrami kod fotografije hrane C sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %

5. ZAKLJUČAK

Promjene crvenog, zelenog i plavog kanala digitalnog zapisa fotografske slike odabranog fotografskog motiva unutar kojih se zadržava ikonički karakter fotografske slike ciljano utječe na njezinu percepciju i interpretaciju u uvjetima optimalne i metamerijske konzumacije.

Utvrđen je odnos između promjene percepcije i interpretacije promjenama vrijednosti plavog, zelenog i crvenog kanala digitalnog zapisa fotografskih slika primjenom odgovarajućih statističkih metodologija, potvrđene su hipoteze i očekivani znanstveni doprinosi te su definirane granice promjena vrijednosti crvenog, zelenog i plavog kanala digitalnog zapisa uz zadržavanje ikoničkog karaktera fotografskih slika konkretnih motiva i sintaktičkih postavki, određene su optimalne promjene vrijednosti crvenog, zelenog i plavog kanala digitalnog zapisa za upravljanje interpretacijom fotografske slike određenog motiva u uvjetima optimalne i metamerijske konzumacije. Potvrđeno je da se promjenama vrijednosti kanala digitalnog zapisa može oblikovati percepcija i utjecati na interpretaciju fotografskih zapisa te su utvrđene granice i vrijednosti promjena kanala po motivu i kanalima koje daju najbolje rezultate u percepciji.

Informacije prikupljene istraživanjem odredile su koji je interakcijski efekt na interpretaciju fotografija o procjeni privlačnosti od strane konzumenata u ovisnosti efekta interakcije promjene vrijednosti kanala i samog kanala zapisa uz pomoć Spearmanovog koeficijenta korelacije koji se između vrijednosti promjene kanala i tipa kanala s procjenom privlačnosti fotografije pokazao pozitivno povezanim s utjecajem promjene plavog kanala na procjenu privlačnosti fotografija i to kod tri motiva: portreta sa selekcijom lica, pejzaža i motiva hrane sa selekcijom (ograničenim područjem promjene kanala). Za motiv portreta i hrane za koje je promjena kanala bila izvršena na čitavoj površini fotografije povezanost nije imala statistički značajan rezultat. U isto vrijeme, promjena zelenog kanala digitalnog zapisa fotografske slike za motive hrane sa selekcijom pokazala se neovisno o vrijednostima promjene kanala negativno povezanom s procjenom privlačnosti fotografije. Drugi motivi kod promjene zelenog kanala nisu imali statistički značajan učinak na procjenu privlačnosti. Procjene privlačnosti kod promjena crvenog kanala nisu imale statistički značajan učinak niti na jednom motivu.

Vrijednosti promjena kanala digitalnog zapisa neovisno o kojem se kanalu promjene radi, crvenom, zelenom ili plavom, kod tropostotnih promjena pojačavanja kod portreta (na cijeloj površini i samo na selekciji lica), pejzaža i fotografija hrane sa selekcijom i s promjenom na cijeloj površini fotografije bile su pozitivno povezane s privlačnosti fotografija.

Tropostotno oslabljivanje bez obzira o kojem se kanalu radi također je dalo veće procjene privlačnosti za portrete sa selekcijom lica, pejzaž i fotografije hrane bez selekcije i sa selekcijom na cijeloj površini fotografije. U ovom slučaju značajna povezanost nije bila utvrđena jedino kod portreta bez selekcije lica. Druge promjene izvan granica tropostotnog oslabljivanja i pojačavanja ili nisu imale značajan efekt s procjenom privlačnosti ili je taj efekt bio negativan što znači da su veće vrijednosti promjene rezultirale nižim procjenama privlačnosti.

Kod provođenja dvosmjernih analiza varijanci (ANOVA) grupirano posebno na motivima sa selekcijom na dijelu površine i na motivima s promjenom na cijeloj površini digitalnog zapisa fotografije utvrđeno je da se kod portreta s promjenom na cijeloj površini fotografije motivi s promjenom u plavom kanalu smatraju privlačnijima od onih u crvenom i zelenom kanalu, i da su portreti s promjenama u crvenom kanalu privlačniji od portreta s promjenama u zelenom kanalu. Rezultati ANOVE vezani su uz uzorke kod kojih su promjene izvršene unutar šestpostotnih pojačavanja i oslabljivanja kanala zbog manjeg broja uzoraka na većim promjenama do kojeg je došlo zbog neispunjavanja uvjeta ikoničnosti, a koji su onemogućili procjenu aritmetičkih sredina privlačnosti fotografija kod određenih kombinacija varijabli kanala i vrijednosti njihovih promjena.

Kod portreta bez selekcije utvrđena je statistička značajnost glavnih efekata varijabli kanala i vrijednosti promjene kanala, odnosno procjena privlačnosti ovisila je o tome koji kanal digitalnog zapisa je promijenjen i za koju vrijednost. Najprivlačniji su portreti s promjenom u plavom kanalu, zatim crvenom pa zelenom. Tropostotno pojačani kanali smatraju se privlačnijim od tropostotno oslabljenih, te šestpostotno oslabljenih i pojačanih kanala, ali istovremeno su se tropostotno oslabljeni i šestpostotno pojačani kanali pokazali jednako privlačnima.

Kod portreta sa selekcijom lica također je utvrđena statistička značajnost glavnih efekata varijabli kanala i njihove vrijednosti promjene. Portreti s promjenom u plavom kanalu procijenjeni su privlačnijim od onih u crvenom i zelenom kanalu, no portreti s izmjenama u crvenom i zelenom kanalu u ovom slučaju nisu imali značajniju statističku razliku u procjeni privlačnosti. Tropostotno pojačani i oslabljeni kanali privlačniji su od šestpostotno pojačanih ili oslabljenih kanala. Između tropostotnih promjena pojačanja i oslabljenja kanala nije uočena značajnija statistička razlika, kao niti između šestpostotnih promjena. Ovdje je utvrđen drugačiji efekt interakcije. Promjene u plavom i crvenom kanalu rezultirale su općenito višim procjenama privlačnosti, ali je u slučaju tropostotnog pojačanja zelenog kanala procjena privlačnosti rezultirala gotovo identičnom procjenom kao kod promjene plavog kanala i višom procjenom

privlačnosti od crvenog kanala, a u slučaju šestpostotnog pojačanja zelenog kanala privlačnost je bila procijenjena nižom nego kod plavog kanala, ali višom nego kod crvenog kanala.

Kod pejzaža kao i kod oba slučaja portreta utvrđena je statistička značajnost efekta varijabli kanala i njihove promjene na procjenu privlačnosti. U ovom slučaju pejzaži s promjenom u plavom kanalu procijenjeni su jednako privlačnim kao pejzaži s promjenom u crvenom kanalu, ali privlačniji od pejzaža s promjenom u zelenom kanalu. Promjene u crvenom i zelenom kanalu nisu pokazale statističku značajnost. Pejzaži s tropostotnim pojačanjem i oslabljenjem kanala procijenjeni su privlačnijim od šestpostotnih pojačanja i oslabljenja kanala. U slučaju pejzaža nije utvrđena ovisnost efekta varijable kanala o razinama varijable promjene vrijednosti kanala što znači da je efekt promjene varijable kanala bio je podjednak na svim razinama varijable promjene vrijednosti kanala.

Kod motiva hrane bez selekcije također je utvrđena značajnost glavnih efekata varijable kanala i njegove vrijednosti promjene te efekta interakcije. Fotografije s promjenom plavog kanala procijenjene su privlačnijima od onih s promjenom crvenog i zelenog kanala, a promjena crvenog i zelenog kanala smatrala se jednako privlačnom. Tropostotno ojačane i oslabljene fotografije smatrane su privlačnijim od onih sa šestpostotnom promjenom oslabljenja i pojačanja, a između tropostotnih promjena oslabljenja i pojačanja kao i šestpostotnih oslabljenja i pojačanja nije utvrđena razlika u privlačnosti. Kod motiva hrane sa selekcijom efekt promjene kanala na procjenu privlačnosti nije bio podjednak na svim razinama promjene kanala. Na razini tropostotnih i šestpostotnih oslabljenja kanala promjene plavog i zelenog kanala smatrane su privlačnijim od promjene crvenog zapisa kanala, dok se tropostotno ojačanje crvenog kanala smatralo privlačnijim od tropostotnih promjena plavog i zelenog kanala, a u slučaju šestpostotne promjene crveni i plavi kanal su smatrani jednako privlačnim, te privlačnijim od promjena u zelenom kanalu.

Kod hrane sa selekcijom na dijelu površine utvrđena je jedino statistička značajnost glavnog efekta varijable kanala digitalnog zapisa dok glavni efekt varijable vrijednosti promjene kanala i efekta interakcije varijable i vrijednosti promjene kanala nije utvrđen. U ovom slučaju fotografije s promjenom u plavom i crvenom kanalu procijenjene su privlačnijima od promjena u zelenom kanalu, s tim da su promjene u crvenom i plavom kanalu smatrane jednako privlačnim. Također ovdje je efekt varijable kanala na privlačnost bio podjednak na svim razinama varijable vrijednosti promjene kanala.

Istraživanjem je bilo obuhvaćeno i ispitivanje utjecaja na interpretaciju fotografskih zapisa te su se na svakom od tri motiva i za svaku od tri korištene fotografija po motivu prikupile procjene

ispitanika konzumenata o optimalnim varijacijama originalnih fotografija. Kod portreta je birana fotografija koja izgleda najprivlačnije, najzdravije i najmlađe.

Kod portreta s promjenom na cijeloj površini slike najprivlačnijim ženskim portretom je odabrana varijacija s tropostotnim pojačanjem plavog kanala, kod muških portreta najprivlačnijim se smatrala varijacija s tropostotno pojačanim plavim kanalom, a kod dječjih portreta najprivlačnijim se smatrala varijacija s tropostotno oslabljenim plavim kanalom. Najzdravijim ženskim portretom proglašena je varijacija s tropostotnim pojačanjem crvenog kanala, najzdravijim muškim portretom varijacija s tropostotno oslabljenim plavim kanalom, a ona je ujedno odabrana i za najzdraviji dječji portret. Najmlađim ženskim portretom odabrana je varijacija s tropostotnim pojačanjem plavog kanala, najzdravijim muškim portretom varijacija s tropostotnim pojačanjem zelenog kanala, a kod dječjeg portreta varijacija s tropostotnim pojačanjem crvenog kanala.

Kod portreta sa selekcijom kože lica najprivlačnijom varijacijom kod ženskog i dječjeg portreta smatrana je ona s tropostotnim oslabljenjem plavog kanala, dok je najprivlačnijim muškim portretom odabrana varijacija s tropostotnim pojačanjem zelenog kanala. Najzdravijom varijacijom kod ženskih i dječjih portreta odabrano je tropostotno oslabljenje plavog kanala (isti obrazac kao i kod najprivlačnijih portreta), a kod muških portreta najzdravijom varijacijom tropostotno oslabljivanje plavog kanala. Najmlađim ženskim portretom odabrana je varijacija sa šestpostotnim oslabljenjem plavog kanala, dok su kod muškog portreta jednak rezultat postigle varijacija s tropostotnim pojačanjem i oslabljenjem plavog kanala. Kod dječjeg portreta s atributom najmlađe odabrane su s podjednakim rezultatom varijacije s tropostotno pojačanim zelenim kanalom i tropostotno oslabljenim plavim kanalom.

Kod pejzažnog motiva birala se samo varijacija s atributom privlačnosti. Kod morskog pejzaža kao najprivlačnija odabrana je varijanta s tropostotnim pojačanjem plavog kanala, kod pejzaža zalaska sunca varijacija s dvanaestpostotnim pojačanjem plavog kanala, te kod pejzažnog motiva polja kao najprivlačnija odabrana je varijacija s tropostotnim oslabljenjem plavog kanala.

Kod fotografija hrane trebalo je izabrati varijacije s atributima najprivlačnije, najukusnije i najsvježije. Kod promjene na cijeloj površini fotografske slike najprivlačnijom varijacijom motiva fotografije ručka je odabrana ona s tropostotnim pojačanjem plavog kanala, najukusnijom varijacija s tropostotnim pojačanjem crvenog kanala, a najsvježijom varijacija s tropostotnim pojačanjem plavog kanala. U slučaju motiva voća najprivlačnijom varijacijom odabrana je ona s tropostotnim pojačanjem plavog kanala, najukusnijom varijacija s tropostotnim pojačanjem crvenog kanala, a najsvježijom varijacije s tropostotnim pojačanjem crvenog i plavog kanala uz isti postotak odabira.

Kod fotografija hrane sa selekcijom na dijelu površine najprivlačnijom varijantom motiva povrća sa selekcijom odabrana je varijacija s tropostotnim oslabljenjem plavog kanala, najukusnijom varijanta s tropostotnim oslabljenjem plavog kanala, a najsvježije one s tropostotnim pojačanjem crvenog kanala. U slučaju motiva voća sa selekcijom najprivlačnijom varijacijom odabrana je ona s tropostotnim pojačanjem plavog kanala, najukusniju varijacija s tropostotnim pojačanjem zelenog kanala što je ujedno odabrano i za najsvježiju varijaciju.

U metamerijskim uvjetima, odnosno promatranjem pod različitim svjetlosnim uvjetima rangiranje prema sličnosti s originalom rezultiralo je sljedećim navedenim odabirima.

Pod Daylight uvjetom odabrano je osam varijacija kao najsličnije u plavom kanalu, pet varijacija kao najsličnije u crvenom kanalu te jedna u zelenom kanalu koja ima isti rezultat kao i jedna varijacija s crvenim kanalom. Tropostotno pojačanje plavog kanala odabrano je kao najsličnije s originalom za ženski portret, muški portret, dječji portret, dječji portret sa selekcijom i pejzaž zalaska sunca. Tropostotno oslabljivanje plavog kanala odabrano je kao najsličnije s originalom kod ženskog portreta sa selekcijom lica i hrane voća sa selekcijom. Tropostotno pojačanje crvenog kanala odabrano je kao najsličnije kod morskog pejzaža, hrane ručka, i hrane voća, a tropostotno oslabljivanje crvenog kanala kod motiva muškog portreta sa selekcijom lica (ujedno i jedini motiv kroz sva tri svjetlosna uvjeta ukupno, a koji je samo u ovom uvjetu postigao jednak rezultat s tropostotnim pojačanjem zelenog kanala i to je jedini odabir zelenog kanala u sva tri svjetlosna uvjeta za sve motive) i kod motiva pejzaža polja. Jedini odabir šestpostotne promjene dogodio se kod odabira hrane povrća sa selekcijom i to unutar plavog kanala.

Pod Storelight uvjetom najveći broj odabranih varijacija koje su ocijenjene sličnim originalu dogodio se u plavom kanalu (deset odabira), a zatim u crvenom kanalu (tri odabira). Varijacije u zelenom kanalu nisu ostvarile niti jedan odabir prema kriteriju najsličnije originalu. Tropostotno pojačanje plavog kanala odabrano je za motive muškog portreta s i bez selekcije lica, dječjeg portreta s i bez selekcije lica, morskog pejzaža i pejzaža zalaska sunca, fotografija hrane ručka i povrća sa selekcijom. Šestpostotno pojačanje plavog kanala odabrano je za varijacije kod motiva ženskog portreta i pejzaža polja. Tropostotna oslabljivanja crvenog kanala odabrana su najsličnijim kod ženskog portreta sa selekcijom lica i fotografije hrane voća sa selekcijom, a varijacija s tropostotnim pojačanjem crvenog kanala odabrana je kod motiva fotografije hrane voća.

U Homelight uvjetu također prevladava odabir varijacija u plavom kanalu (odabir kod devet motiva), a zatim slijedi odabir za varijacije u crvenom kanalu za ukupno četiri motiva. Tropostotna pojačanja plavog kanala odabrana su za varijacije kod motiva ženskog portreta,

dječjeg portreta sa selekcijom lica te sva tri motiva pejzaža. Šestpostotno pojačanje plavog kanala odabrano je za varijacije kod motiva muškog portreta, dječjeg portreta i hrane s selekcijom. Jedino tropostotno oslabljivanje plavog kanala odabrano je kao varijacija kod motiva s fotografijom voća sa selekcijom. Kod promjena u crvenom kanalu odabrane su po dvije varijacije sa tropostotno pojačanim (za motive fotografija hrane ručka i voća sa izmjenom na cijeloj površini slike) i oslabljenim crvenim kanalom (za motive muškog i ženskog portreta sa selekcijom).

Kod metamerijskih uvjeta promatranja proveden je također odabir najprivlačnijih fotografija za svaki motiv pod svakim svjetlosnim uvjetom za sve varijacije. Za Daylight uvjet crveni i plavi kanal su pokazali veću privlačnost od zelenog kanala, ali bez statističke razlike između crvenog i plavog kanala te su tropostotno pojačanje i oslabljenje smatrani jednako privlačnim. Najviše bodova za privlačnost u Daylight uvjetu rangiranjem osvojile su varijacije kako slijedi: tropostotno pojačanje crvenog kanala (za motive dječji portret sa selekcijom lica, pejzaž polja, fotografiju ručka, povrća sa selekcijom i voća s izmjenom na cijeloj površini slike), tropostotno oslabljenje crvenog kanala (ženski i muški portret sa selekcijom te voće sa selekcijom), tropostotno pojačanje plave (za motive ženskog, muškog i dječjeg portreta te voća sa selekcijom, tropostotno oslabljenje plavog kanala za motiv zalaska sunca, šestpostotno oslabljenje plavog kanala za motiv ženskog portreta sa selekcijom lica, devetpostotno pojačanje crvenog kanala za motiv pejzaža polja i tropostotno oslabljivanje zelenog kanala za motiv ručka.

Za Storelight izvor svjetla je slična situacija kao i za Homelight izvor svjetla, osim što ovdje nije utvrđena značajnost efekta interakcije. Ovdje su također promjene crvenog i plavog kanala imale veći učinak na privlačnost od onih u zelenom kanalu. Najprivlačnijim varijacijama u Storelight uvjetu rangirane su: tropostotno pojačanje plavog kanala (za motive ženskog, muškog i dječjeg portreta s izmjenom na cijeloj površini slike, muškog portreta sa selekcijom lica i fotografiji voća s izmjenom na cijeloj površini, tropostotno oslabljenje plavog kanala (za motive ženskog portreta sa selekcijom lica i povrća sa selekcijom, tropostotno pojačanje crvenog kanala (za motive muškog portreta s izmjenom na cijeloj površini i dječjeg portreta s izmjenom na površini lica, šestpostotno pojačanje plavog kanala za motiv morskog pejzaža, tropostotno pojačanje zelenog kanala za motive zalaska sunca i povrća sa selekcijom, šestpostotno pojačanje, tropostotno oslabljenje i dvanaestpostotno pojačanje plavog kanala za motiv ručka.

Za Homelight izvor svjetla dobivena je ponovno statistička značajnost efekta kanala i vrijednosti promjene te interakcijskog učinka. Varijacije s promjenama crvenog i plavog kanala procijenjene su privlačnijima od onih u zelenom kanalu, a one same smatrane su jednako

privlačnima. Najprivlačnijim varijacijama po motivima odabrani su: tropostotno pojačanje plavog kanala za motive ženskog portreta s i bez selekcije lica, muškog i dječjeg portreta, morskog pejzaža, voća sa selekcijom, tropostotno pojačanje crvenog kanala za motive ženskog i dječjeg portreta sa selekcijom lica, ručka, povrća sa selekcijom i voća, tropostotno oslabljenje plavog kanala za motive muškog portreta sa selekcijom lica i portreta pejzaža, devetpostotno pojačanje plavog kanala za motiv pejzaža zalaska sunca, tropostotno oslabljenje zelenog kanala za motiv pejzaža polja, voća s i bez selekcije, šestpostotno pojačanje zelenog kanala za motiv voća sa selekcijom.

Iz navedenog se može zaključiti da crveni i plavi kanal općenito daju najviše odabira po kriteriju privlačnosti fotografija u različitim svjetlosnim uvjetima. Također, kod nekih je motiva jasno vidljivo da utjecaj na promjenu samo jednog kanala osigurava da fotografska slika dobro funkcionira u sva tri svjetlosna uvjeta što se može iskoristiti kod primjene promotivnih fotografskih slika koje se konzumiraju u različitim svjetlosnim uvjetima te se tako osigurava da taj način obrađena slika izgleda dobro i prihvatljivo u odabranim, a istovremeno različitim, uvjetima konzumacije.

Iz mjernih se ispitivanja može zaključiti da je ukupna promjena boja to manja što je manji postotak promjene varijacije kanala. Posebno, najbolje rezultate dale su promjene u plavom pa zatim u crvenom kanalu, dok su promjene u zelenom kanalu dale najlošije rezultate i najveća odstupanja od granice prihvatljivosti $\Delta E_{00} = 6$ te je u tom kanalu zapisa bilo i najviše fotografija koje su izbačene iz istraživanja kriterijem odabira samo onih fotografija koje i dalje zadržavaju ikoničnost. Također, kod motiva morskog pejzaža, dječjeg portreta s izmjenom na cijeloj površini slike i fotografije hrane ručka uočeno je da je tolerancija na odstupanje ΔE_{00} bila veća te su neke fotografije prošle kriterij ikoničnosti unatoč prelasku granice tolerancije $\Delta E_{00} = 6$.

Nakon provedenih svih ispitivanja i mjerenja, općenito, može se zaključiti da promjene plavog i crvenog kanala daju najbolje rezultate te da statistička analiza potvrđuje rezultate mjernih ispitivanja. Kod motiva pejzaža toleriraju se veća mjerna odstupanja u razlici boja nego kod motiva portreta što je bilo i očekivano. Kod motiva hrane promjena kanala bila je skoro jednako zastupljena u svakom od tri kanala te se može reći da je promjena vezana uz osobni izbor pojedinca, a ovisno o uvjetima promatranja, odnosno o izvoru svjetla.

Komparacija rezultata vizualnih procjena eksperata i konzumenata fotografskih slika te standardnih određivanja ukupne razlike boja (ΔE_{00}) i analize histograma digitalnih zapisa fotografskih slika također upućuje na potrebu daljnjeg povezivanja mjernih karakteristika fotografskih slika i njihovih digitalnih zapisa sa semantičkim i sintaktičkim svojstvima konkretne fotografske slike.

6. LITERATURA

[1] M. Mikota and I. Pavlović, “ANALIZA SEMANTIČKIH SVOJSTAVA FOTOGRAFIJA OBJAVLJENIH U TISKANIM MEDIJIMA I NA INTERNETU and \#8211; USPOREDBA STANJA U HRVATSKOJ I SVIJETU,” pp. 68–70, 2008.

[2] M. Periša, D. Čerepinko, and M. Milković, “Analiza metodike prezentacije informacija u hrvatskim tiskanim medijima primjenom teorijskih pravila Gestalta,” pp. 300–309, 2010.

[3] M. Mikota, R. Kulčar, and N. Knešaurek, “Reproduction of Photographic Illustration Color in Eletronic Editions,” 2005.

[4] M. Mikota, I. Pavlović, and A. Momčilović, “Semantic and syntax of ecologically engaged photography,” Z. Bolanca and M. Mikota, Eds. Grafički fakultet ; Matica hrvatska, Ogranak : Pulps and Paper Institute, 2005, pp. 23–36.

[5] R. Hirsch, *Seizing the Light: A social & Aestetic History of Photography"*. Taylor ans Fancis Online, 2017.

[6] M. Mikota, M. Brozović, and I. Pavlović, “Kvaliteta fotografske prezentacije modnih noviteta u medijima vanjskog oglašavanja,” *Tekst. časopis za Tekst. Tehnol. i konfekciju*, vol. 57, no. 9, pp. 457–464, 2008.

[7] M. Milković, N. Mrvac, and G. Kozina, “INFORMACIJSKI SUSTAVI ZA UPRAVLJANJE BOJAMA.” Veleučilište u Varaždinu, p. 73, 2011.

[8] M. Mikota, *Kreacija fotografijom*. Vedis, 2000.

[9] A. E. Eckstut Joann, *Secret Language of Color: Science, Nature, History, Culture, Beauty of Red, Orange, Yellow, Green, Blue, & Violet*. New York: BDL Publisher, 2013.

[10] M. Mikota, I. Pavlović, and M. Brozović, “Influence of the Lighting on the Portrait Photographs Shot with the Digital Photography System,” B. Katalinic, Ed. DAAAM International Vienna, 2008, pp. 463–476.

[11] M. Mikota and I. Pavlović, “ISO SPEED AS THE TECHNICAL AND CREATIVE ELEMENT OF THE DIGITAL PORTRAIT PHOTOGRAPHS,” DAAAM International Vienna, 2010, pp. 9–18.

[12] M. Kardum, “Znanost o slici: Discipline, teme, metode (Klaus Sachs-Hombach),” vol. vol.VIII, no. br. 16/17, p. str. 207-210, 2009, [Online]. Available: https://hrcak.srce.hr/61670.

[13] M. Periša, N. Mrvac, and M. Mikota, “The Visual Grammar of Photographic Images

Produced by Media Convergence," pp. 647–667, 2015.

[14] E. W. Averill, "The phenomenological character of color perception," *Philos. Stud. An Int. J. Philos. Anal. Tradit.*, vol. 157, no. 1, pp. 27–45, 2012, doi: 10.1007/sl 1098-010-9616-y.

[15] N. Tanhofer, *O boji na filmu i srodnim medijima*. Zagreb: Novi Liber, 2000.

[16] A. Rodney, *Color Management for Photographers*. Burlington: Focal Press, 2012.

[17] E. Langford, Michael; Bilissi, *Langford's Advanced Photography, Eighth Edition: The guide for aspiring photographers (The Langford Series) 8th Edition*. Focal Press.

[18] J. Hedgecoe, *The Book Of Photography*. Dk Pub, 2005.

[19] N. Mrvac, K. Petrić, and M. Matijević, "Utjecaj boja na optičku težinu portretne fotografije," pp. 389–402, 2014.

[20] P. Messaris, *Visual Persuasion: The Role of Images in Advertising*. SAGE Publications, Inc., 1997.

[21] M. Mikota, I. Pavlović, and M. Matijević, "Effect of the changes in the RGB digital image channel on the perception of fashion photography while retaining its iconicity," *Tekst. časopis za Tekst. Tehnol. i konfekciju*, vol. 64, no. 1–2, pp. 19–24, 2015.

[22] M. Mikota, M. Matijević, and I. Pavlović, "Colour reproduction analysis of portrait photography in cross-media system: image on the computer monitor–electrophotographic printing," *Imaging Sci. J.*, vol. 64, no. 6, pp. 299–304, 2016, doi: 10.1080/13682199.2016.1184875.

[23] P. J. Braun, Karen M. ; Fairchild, Mark D; Alessi, "Viewing techniques for cross-media image comparisons," *Colour, Res. Appl.*, vol. 21, no. 1, pp. 6–17, 1996, doi: https://doi.org/10.1002/(SICI)1520-6378(199602)21:1<6::AID-COL1>3.0.CO;2-%23.

[24] M. Mikota and I. Pavlović, "UTJECAJ PRIMJENE POLARIZACIJSKOG FILTERA NA BOJE SNIMLJENE FOTOGRAFIJE," pp. 473–478, 2012.

[25] M. Stupić, I. Pavlović, and M. Mikota, "Color changes in system motive - digital photography - digital printing," pp. 69–75, 2007.

[26] I. Pavlović, M. Tomiša, and M. Matijević, "UTJECAJ IZBORA DOD Hi Fi BUBBLE JET PODLOGE ZA ISPIS NA STANDARDNE BOJE REALNIH FOTOGRAFSKIH MOTIVA," pp. 261–269, 2013.

[27] I. Pavlović, T. Žeželj, M. Mikota, and J. Vlašić, "Analiza manipulacije portretnom fotografskom slikom promjenama vrijednosti R kanala zapisa," pp. 278–284, 2016.

[28] "Svjetlost." https://hr.wikipedia.org/wiki/Svjetlost.

[29] "Oko." https://hr.wikipedia.org/wiki/Oko.

[30] “Štapići i čunjići.” http://physics.mef.hr/Predavanja/seminar_optika/main1e.html.

[31] “CIE 1931 prostor boja,” *Wikipedia*. https://en.wikipedia.org/wiki/CIE_1931_color_space.

[32] “Kvalitativne metode ispitivanja reprodukcije boja,” *Grafički fakultet*. http://fotoprocesi.grf.unizg.hr/media/Predavanja - Kvalitivne metode ispitivanja reprodukcije boja_2014.pdf.

[33] “Osnove boja,” *Graficki fakultet*. http://repro.grf.unizg.hr/media/download_gallery/OSNOVE O BOJI.pdf.

[34] “Munsell colour system,” *Britannica, The Editors of Encyclopaedia. Encyclopedia Britannica, 1 Feb. 2018,*. https://www.britannica.com/science/Munsell-color-system.

[35] “NCS kolor sistem.” https://ncscolour.com/ncs/.

[36] “Ostwaldov sustav boja,” *Wikipedia*. https://en.wikipedia.org/wiki/Ostwald_color_system.

[37] “Ostwaldov sistem (trokut),” *Britannica, The Editors of Encyclopaedia.* https://www.britannica.com/science/Ostwald-color-system.

[38] “DIN sistem,” *colorsystem*. https://www.colorsystem.com/?page_id=948&lang=en.

[39] “Pantone,” *Pantone*. https://www.pantone.com/eu/en/formula-guide-coated-uncoated.

[40] “Pantone Goe System,” *Wikipedia*. https://en.wikipedia.org/wiki/Pantone.

[41] “CIE komisija,” *lisungroup*. https://hr.lisungroup.com/standardi/cie-međunarodna-komisija-za-osvjetljenje.html.

[42] M. Matijević, “Vizualni efekt proširivanja i simultanog kontrasta u grafičkoj komunikaciji,” Grafički fakultet, Zagreb, 2013.

[43] M. Milković, I. Zjakić, and D. Vusić, “Kolorimetrija u multimedijskim komunikacijama.” Veleučilište u Varaždinu, p. 115, 2010.

[44] “Miješanje boja.” https://hr.wikipedia.org/wiki/Miješanje_boja.

[45] H. Helmholtz, “Photometric Aspects of Visible Light and Colours,” in *Microclimate for Cultural Heritage*, 2019, pp. 273–299.

[46] L. Ronnier, Ed., *Encyclopedia of Color Science and Technology*. Springer-Verlag New York, 2016.

[47] M. Milković, N. Mrvac, and D. Vusić, “Vizualna psihofizika i dizajn.” Veleučilište u Varaždinu, p. 105, 2010.

[48] “Adobe Stock Images.” https://stock.adobe.com/photos.

[49] J. Kučko, “foto Josip Kučko Moto utrke.” http://www.racing.hr/.

[50] R. Cornelius, “Prvi napravljen autoportret.” https://petapixel.com/2011/07/19/the-first-

self-portrait-photo-ever-made/.

[51] Wikimedia Commons, “Prva fotografija - View from the Window at Le Gras, Joseph Nicéphore Niépce.” By Nicéphore Niépce - Harry Ransom Center's Gernsheim collection, The University of Texas at Austin, Public Domain, https://commons.wikimedia.org/w/index.php?curid=25274651.

[52] Wikimedia Commons, “Edward Steichen - Moonlight.” https://en.wikipedia.org/wiki/The_Pond—Moonlight.

[53] A. CAIN, “Food Photography Didn’t Start on Instagram—Here’s Its 170-Year History.” httpswww.artsy.netarticleartsy-editorial-food-photography-start-instagram-170-year-historyamp.

[54] B. Long, *Complete Digital Photography: 9th Edition*. CDP Press, 2018.

[55] M. Maričević, I. Pavlović, M. Mikota, and A. Divjak, “Analiza metoda forenzike digitalnog zapisa fotografije,” 2013.

[56] T. S. Holst, G.C.; Lomheim, *CMOS/CCD Sensors and Camera Systems*. SPIE_The Internationl Society for Optical Engineering, 2011.

[57] P. W. Rabbani, M.; Jones, *Digital Image Compression Techniques*. SPIE Press, 1991.

[58] S. D. Anderson, “Digital Image analysis: analytical framework for authenticating digital images,” University of Colorado, 2011.

[59] L. Green, Phil; MacDonald, *Colour Engineering: Achieving Device Independent Colour*. Chichester, UK: John Weily & Sons, 2002.

[60] M. Mikota, “Studija sustava digitalne portretne fotografije,” University of Zagreb Faculty of Graphic Arts, 2007.

[61] “OLED monitori.” https://hr.wikipedia.org/wiki/OLED_televizori.

[62] “CRT monitori.” https://hr.wikipedia.org/wiki/CRT_zaslon.

[63] “LCD tehnologija.” https://hr.wikipedia.org/wiki/LCD.

[64] “Adobe Photoshop 2021 user guide.” https://helpx.adobe.com/photoshop/user-guide.html.

[65] “ISO 3664:2009 Graphic technology and photography — Viewing conditions.” https://www.iso.org/standard/43234.html.

[66] A. K. R. Choudhury, *Principles of Colour and Appearance Measurement 1st Edition*. Woodhead Publishing, 2014.

[67] D. F. Malhotra, Naresh K. ; Birks, *Marketing Research: An Applied Approach*. New York, 2007.

[68] J. Horvat and J. Mijoč, “Osnove statistike.” Naklada Ljevak i Sveučilište Josipa Jurja

Strossmayera u Osijeku, p. 680, 2012.

[69] “Canon EOS 5D Mk III.” https://www.canon.hr/for_home/product_finder/cameras/digital_slr/eos_5d_mark_iii/.

[70] M. Mikota and I. Pavlović, “IMPACT OF RENDERING WITH PERCEPTUAL INTENTS ON COLORIMETRIC VALUES AND IMPRESSION OF PORTRAIT PHOTOGRAPHS,” pp. 101–104, 2009.

[71] “Biometrijski portret.” https://mup.gov.hr/UserDocsImages/BannerZona/Upute za fotografije 2013 (2).pdf.

[72] “Temeljni statisticki pojmovi.” http://www.unizd.hr/portals/4/nastavni_mat/2_godina/statistika/statistika_01.pdf.

[73] “TCL.” https://www.tcl.com/bo/en/products/p615/p615-55.html.

[74] “TCL Android specifications.” https://www.displayspecifications.com/en/model/d6992143.

[75] “Ishihara test.” https://en.wikipedia.org/wiki/Ishihara_test.

[76] “Surveymonkey.” https://www.surveymonkey.com/.

[77] “Epson SURECOLOR SC-P9500 SPECTRO.” https://www.epson.hr/products/printers/large-format-printers/surecolor-sc-p9500-spectro.

[78] “Tecco Lustre Photo Paper.” https://www.tecco.de/product/pl285-luster/.

[79] “X Rite Judge II.” https://www.xrite.com/-/media/xrite/files/manuals_and_userguides/j/judge_ii_manual_en.pdf.

[80] “ANOVA analiza.” https://en.wikipedia.org/wiki/Analysis_of_variance.

[81] S. van der Walt *et al.*, “scikit-image: image processing in {P}ython,” *PeerJ*, vol. 2, p. e453, 2014, doi: 10.7717/peerj.453.

[82] A. Poljičak, “Call1st0 / color-diff-analysis,” 2021. https://github.com/Call1st0/color-diff-analysis.git.

[83] “CIE 2000 color calculator.” http://www.brucelindbloom.com/.

7. PRILOZI

7.1.1. PRILOG 1 -POPIS SLIKA

Slika 1 Prikaz originala (a) te plavog (b), zelenog (c) i crvenog (d) kanala digitalnog zapisa slike 2
Slika 2 Spektar elektromagnetskih valova s istaknutim dijelom vidljive svjetlosti [28] 6
Slika 3 Shematski presjek građe ljudskog oka [29] te prikaz štapića i čunjića [30] 7
Slika 4 Prikaz tona, svjetline i zasićenja boje 7
Slika 5 Primjer metamerije: a) izazvane izvorom svjetla i b) izazvane promatračem [32] 8
Slika 6 Munsellov kolor sustav [34] 9
Slika 7 NCS sustav boja [35] 10
Slika 8 Ostwaldov sustav boja [37] [36] 10
Slika 9 DIN kolor sistem, DIN kolor karta i DIN sustav boja [38] 11
Slika 10 Primjer Pantone karte boja [39] 11
Slika 11 CIE standardna rasvjeta[33] 12
Slika 12 CIE funkcija podudarnosti standardnog promatrača [31] 12
Slika 13 CIE 1931 dijagram kromatičnosti 13
Slika 14 CIE Lab dijagram i prostor boja 14
Slika 15 Dijagram kromatičnosti ab [32] 14
Slika 16 Kolorimetrijska razlika boja - CIE Lab model boja 15
Slika 17 Standardna tablica boja X-Rite 17
Slika 18 Prikaz aditivne i suptraktivne sinteze boja [43] 17
Slika 19 Usporedba doživljaja boje, tristimulusne i spektrofotometrijske metode mjerenja [33] 18
Slika 20 Razlika mjerenja kolorimetra i spektrofotometra 19
Slika 21 Planovi: a) total, b) srednji plan, c) bliži plan, d) krupni plan i e) detalj 21
Slika 22 Kut snimanja (rakurs): a) shema rakursa, b) normalna vizura, c) donji rakurs, d) gornji rakurs, e) žablja perspektiva f) ptičja perspektiva 22
Slika 23 Vrste perspektiva: a) geometrijska, b) vertikalna, c) atmosferska, d) kolorističkа, e) semantička 23
Slika 24 Pravila optičke ravnoteže: a) simetrija, b) stabilnost, c) ritam, d) zlatni rez 24
Slika 25 Područja interesa unutar plohe (I - najveća percepcijska vrijednost plohe i II - najmanja percepcija vrijednost plohe) 24
Slika 26 Prikaz: a) konstrukcija točke interesa; b) Sfera, zona i točka interesa, c) označene sfera zona i točka interesa 25

Slika 27 Primjer korištenja linija na fotografiji: a) stvarne linije, b) zamišljene linije, c) psihološke linije 25
Slika 28 Tonovi u kolor fotografiji: a) Kompozicija zatvorena tonovima, b) high key fotografija[48], c) low key fotografija 26
Slika 29 Kompozicija temeljena na bojama: a)sklad boja, b) kontrast boja, c) izdvojena boja, d) prevladavajuća boja 27
Slika 30 Ikonički (a)[49], indeksični (b) [48] i simbolički karakter (c) [49] 28
Slika 31 Robert Cornelius, Autoportret, dagerotipija, 1839. [50] 30
Slika 32 a) pločica bitumena premazana uljem korištena za ekspoziciju i b) Nicéphore Niépce, Pogled kroz prozor [51] 31
Slika 33 Edward Steichen, Moonlight - The Pond, 1904. [52] 32
Slika 34 William Henry Fox Talbot, A Fruit Piece, 1845. Image via Wikimedia Commons [53] 33
Slika 35 Shema procesa nastajanja digitalnog fotografskog zapisa fotografije [55] 34
Slika 36 Adobe RGB i sRGB prostor boja u CIE 1931 dijagramu kromatičnosti [60] 36
Slika 37 Vrste renderiranja 36
Slika 38 Utjecaj odabira monitora na obradu fotografije: a) fotografija portreta i standardne tablice boja obrađena uz gamma 2,2 (PC) i b) fotografija portreta i standardne tablice boja obrađena uz gamma 1,8 (Apple Macintosh) [60] 38
Slika 39 Digitalni zapis fotografije učitan u Adobe Photoshop(a) i Adobe Lightroom (b) 39
Slika 40 Predobrada fotografije u Camera Raw programu: a) podešavanje tonova (tonska krivulja), b)izoštravanje, uklanjanje šuma 40
Slika 41 Adobe Lightroom, postupak izrade maske: a)odabir automatskog odabira maske objekta, b) procesuiranje maske, c) u slučaju slabijih karakteristika hardverskog sustava javlja se greška, d) odrađena automatska selekcija subjekta, e) nadopunjena selekcija korištenjem brush opcije 41
Slika 42 Histogram digitalnog zapisa fotografije: a) normalno eksponirana fotografija b) simulacija preeksponirane fotografije c) simulacija podeksponirane fotografije 42
Slika 43 Dijelovi histograma [64] 43
Slika 44 Testni motivi snimljeni za istraživanje: a) motivi portreta (ženski, muški i dječji portret) snimljeni za istraživanje, b) motivi hrane snimljeni za istraživanje i c) motivi pejzaža snimljeni za istraživanje 45
Slika 45 Primjer stvaranja promjene na primjeru fotografije dječjeg portreta: a) od -3% u crvenom kanalu i b) od -12% u plavom kanalu 46

Slika 46 Ishihara test raspoznavanja boja 47
Slika 47 Fotografije ženskog portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PŽ) i b) na selekciji lica (PŽS) 50
Slika 48 Fotografije muškog portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PM) i b) na selekciji lica (PMS) 51
Slika 49 Fotografije dječjeg portreta s 24 varijacije po svim kanalima napravljene: a) na cijeloj površini fotografije (PD) i b) na selekciji lica (PDS) 52
Slika 50 Fotografije s 24 varijacije po svim kanalima: a) pejzaž LA, b) pejzaž LB i c) pejzaž LC 53
Slika 51 Fotografije s 24 varijacije po svim kanalima za a) hranu A s promjenom na cijeloj površini slike, b) hranu B s promjenom samo na selekciji slike 54
Slika 52 Fotografije sa 24 varijacije po svim kanalima za a) hranu C s promjenom na cijeloj površini slike i b) hranu C s promjenom samo na selekciji slike 55
Slika 53 Set fotografija ženskog portreta pripremljen za gledanje ekspertima: a) s varijacijom na cijeloj površini digitalnog zapisa slike i b) sa varijacijom na selekciji lica 57
Slika 54 Set fotografija varijacija muškog portreta (PM) pripremljen za gledanje ekspertima 58
Slika 55 Set fotografija varijacija muškog portreta sa selekcijom (PMS) pripremljen za gledanje ekspertima 58
Slika 56 Set fotografija varijacija dječjeg portreta pripremljen za gledanje ekspertima 59
Slika 57 Set fotografija varijacija dječjeg portreta sa selekcijom lica pripremljen za gledanje ekspertima 59
Slika 58 Set fotografija varijacija morskog pejzaža (LA) pripremljen za gledanje ekspertima 60
Slika 59 Set fotografija varijacija pejzaža zalaska sunca (LB) pripremljen za gledanje ekspertima 60
Slika 60 Set fotografija s varijacijama pejzaža polja s izrazitim bojama (LB) pripremljen za gledanje ekspertima 61
Slika 61 Set fotografija hrane ručka (HA) s varijacijama na cijeloj površini pripremljen za gledanje ekspertima 61
Slika 62 Set varijacija s fotografijom hrane povrća sa selekcijom (HBS) pripremljen za gledanje ekspertima 62
Slika 63 Set fotografija varijacija fotografija hrane C pripremljen za gledanje ekspertima 62
Slika 64 Set varijacija fotografija hrane voća sa selekcijom (HCS) pripremljen za gledanje ekspertima 63
Slika 65 Eksperti iz područja fotografije i vizualnih umjetnosti gledaju uzorke 63

Slika 66 Prva stranica anketnog upitnika za eksperte 64
Slika 67 Set fotografija pripremljen za gledanje ispitanicima konzumentima na primjeru seta fotografija ženskog portreta bez selekcije lica: a) original, b) set s fotografijama za koje su ispitanici eksperti zaključili da zadržavaju stupanj ikoničnosti 65
Slika 68 Ispitanici konzumenti u trećoj fazi istraživanja pregledavaju fotografije 66
Slika 69 Survey monkey anketa -dio, primjer 66
Slika 70 Dio uzoraka pripremljenih za ispitivanje u kućici za promatranje Judge II 67
Slika 71 Eksperti promatraju uzorke pod različitim svjetlima u kućici za promatranje Judge II 68
Slika 72 Primjer anketnog obrasca za eksperte za 4. dio istraživanja 69
Slika 73 Prosječna privlačnost portreta ovisno o kanalu i vrijednost promjene kanala digitalnog zapisa 82
Slika 74 Prosječna privlačnost portreta sa selekcijom s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa 85
Slika 75 Prosječna privlačnost pejzaža s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa 87
Slika 76 Prosječna privlačnost fotografija hrane ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa 90
Slika 77 Prosječna privlačnost fotografija hrane sa selekcijom ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa 92
Slika 78 Učestalost odabira uzoraka portreta bez selekcije na atributima privlačnosti, zdravlja i starosti 94
Slika 79 Učestalost odabira uzoraka portreta sa selekcijom lica na atributima privlačnosti, zdravlja i starosti 95
Slika 80 Učestalost odabira uzoraka pejzaža na atributu privlačnosti 97
Slika 81 Učestalost odabira uzoraka fotografija hrane bez selekcije na atributima privlačnosti, okusa i svježine 98
Slika 82 Učestalost odabira uzoraka fotografija hrane sa selekcijom na atributima privlačnosti, okusa i svježine 99
Slika 83 Prosječna privlačnost fotografija u daylight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa 105
Slika 84 Prosječna privlačnost fotografija u storelight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa 108

Slika 85 Prosječna privlačnost fotografija u homelight uvjetu ovisno o kanalu i vrijednostima promjene kanala digitalnog zapisa 110
Slika 86 Primjer izračuna razlike boja ΔE_{00} za tropostotnu promjenu crvenog kanala kod svijetle boje kože u Lindbloom kalkulatoru boja [83] 124
Slika 87 Histogrami kod fotografije ženskog portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 % 132
Slika 88 Histogrami kod fotografije ženskog portreta sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 % 133
Slika 89 Histogrami kod fotografije muškog portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 % 134
Slika 90 Histogrami kod fotografije muškog portreta sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 % 135
Slika 91 Histogrami kod fotografije dječjeg portreta bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 % 136
Slika 92 Histogrami kod fotografije dječjeg portreta sa selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 137
Slika 93 Histogrami kod fotografije pejzaža A bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 138
Slika 94 Histogrami kod fotografije pejzaža B bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 139
Slika 95 Histogrami kod fotografije pejzaža C bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 140
Slika 96 Histogrami kod fotografije hrane A bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 141
Slika 97 Histogrami kod fotografije hrane B sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 142
Slika 98 Histogrami kod fotografije hrane C bez selekcije s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 143
Slika 99 Histogrami kod fotografije hrane C sa selekcijom s promjenama provedenim kroz oslabljivanje i pojačavanje crvenog, zelenog i plavog kanala za 3, 6, 9 i 12 %..... 144

7.1.2. PRILOG 2 - POPIS TABLICA

Tablica 1. Vrednovanje kolorimetrijske razlike boja prema ΔE_{00} 16
Tablica 2 Motivi fotografija i dodijeljene šifre za svaki motiv i njegovu varijaciju za svaki kanal 56
Tablica 3 Različiti izvora svjetla koji se nalaze u kućici za promatranje Gretag Macbeth Judge II 68
Tablica 4a) Tablica boja s promjenama vrijednosti crvenog, zelenog i plavog kanala (3 i 6 posto) 70
Tablica 5 Šifre fotografija za koje su eksperti zaključili da više ne zadržavaju ikonički karakter 73
Tablica 6 Distribucija portreta koji nisu ispunili zahtjev zadržavanja ikoničkog karaktera s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa 74
Tablica 7 Distribucija portreta (sa selekcijom lica) koji nisu zadržali ikonički karakter s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa 74
Tablica 8 Distribucija pejzaža koji nisu zadržali ikonički karakter s obzirom na kanal i vrijednost promjene digitalnog zapisa 75
Tablica 9 Distribucija fotografija hrane koje nisu zadržale ikonički karakter s obzirom na kanal i vrijednost promjene kanala digitalnog zapisa 76
Tablica 10 Distribucija fotografija hrane (sa selekcijom) koje nisu zadržale ikonički karakter s obzirom na kanal i vrijednost promjene digitalnog zapisa 76
Tablica 11 Povezanost kanala, kao i vrijednosti promjene kanala digitalnog zapisa i privlačnosti fotografije 78
Tablica 12 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku portreta 80
Tablica 13 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta ovisno o kanalu digitalnog zapisa 80
Tablica 14 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta s obzirom na kanal digitalnog zapisa 81
Tablica 15 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta ovisno o vrijednostima promjene kanala digitalnog zapisa 81
Tablica 16 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta s obzirom na vrijednost promjene kanala digitalnog zapisa 81
Tablica 17 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku portreta sa selekcijom 83

Tablica 18 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta sa selekcijom ovisno o kanalu digitalnog zapisa 83
Tablica 19 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta sa selekcijom s obzirom na kanal digitalnog zapisa 83
Tablica 20 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti portreta sa selekcijom ovisno o vrijednostima promjene kanala digitalnog zapisa 84
Tablica 21 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti portreta sa selekcijom s obzirom na vrijednost promjene kanala digitalnog zapisa 84
Tablica 22 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku pejzaža..... 85
Tablica 23 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti pejzaža ovisno o kanalu digitalnog zapisa 86
Tablica 24 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti pejzaža s obzirom na kanal digitalnog zapisa 86
Tablica 25 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti pejzaža ovisno o vrijednostima promjene kanala digitalnog zapisa 86
Tablica 26 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti pejzaža s obzirom na vrijednost promjene kanal digitalnog zapisa 87
Tablica 27 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku fotografija hrane... 88
Tablica 28 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o kanalu digitalnog zapisa 88
Tablica 29 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na kanal digitalnog zapisa..... 88
Tablica 30 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o vrijednostima promjene kanala digitalnog zapisa..... 89
Tablica 31 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na vrijednost promjene kanal digitalnog zapisa..... 89
Tablica 32 Prikaz rezultata dvosmjerne 3x4 analize varijance na uzorku fotografija hrane sa selekcijom..... 90
Tablica 33 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o kanalu digitalnog zapisa 91
Tablica 34 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na kanal digitalnog zapisa..... 91
Tablica 35 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija hrane ovisno o vrijednostima promjene kanala digitalnog zapisa..... 91

Tablica 36 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija hrane s obzirom na vrijednost promjene kanal digitalnog zapisa..... 91
Tablica 37 Rangovi kod fotografija prema zadržavanju ikoničnosti u odnosu na original kod tri različita izvora svjetla..... 100
Tablica 38 Prikaz izbora najprivlačnijih varijacija po motivu i izvoru svjetla od strane eksperata 102
Tablica 39 Prikaz rezultata dvosmjerne 3x4 analize varijance u daylight metamerijskom uvjetu 103
Tablica 40 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u daylight uvjetu ovisno o kanalu digitalnog zapisa 104
Tablica 41 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u daylight uvjetu s obzirom na kanal digitalnog zapisa 104
Tablica 42 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u daylight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa 104
Tablica 43 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u daylight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa 105
Tablica 44 Prikaz rezultata dvosmjerne 3x4 analize varijance u storelight metamerijskom uvjetu..... 106
Tablica 45 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u storelight uvjetu ovisno o kanalu digitalnog zapisa 106
Tablica 46 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u storelight uvjetu s obzirom na kanal digitalnog zapisa 106
Tablica 47 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u storelight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa 107
Tablica 48 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u storelight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa 107
Tablica 49 Prikaz rezultata dvosmjerne 3x4 analize varijance u homelight metamerijskom uvjetu..... 108
Tablica 50 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u homelight uvjetu ovisno o kanalu digitalnog zapisa 109
Tablica 51 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u homelight uvjetu s obzirom na kanal digitalnog zapisa 109
Tablica 52 Aritmetičke sredine i intervali pouzdanosti procjena privlačnosti fotografija u homelight uvjetu ovisno o vrijednostima promjene kanala digitalnog zapisa 109

Tablica 53 Post-hoc usporedbe značajnosti razlika aritmetičkih sredina procjena privlačnosti fotografija u homelight uvjetu s obzirom na vrijednost promjene kanal digitalnog zapisa ... 110
Tablica 54: a) Plavi kanal oslabljen za 12% i b) Plavi kanal pojačan za 12%. a) ... 112
Tablica 55 Crveni kanal sa pojačanom vrijednosti za 12% ... 113
Tablica 56 Zeleni kanal pojačan za 9%. ... 113
Tablica 57 Plavi kanal oslabljen i pojačan za 9%. ... 114
Tablica 58 Crveni kanal oslabljen i pojačan za 9% ... 115
Tablica 59 Plavi kanal oslabljen i pojačan za 6%. ... 116
Tablica 60 Crveni kanal oslabljen i pojačan za 6% ... 117
Tablica 61 Zeleni kanal oslabljen i pojačan za 6%. ... 118
Tablica 62 Crveni kanal oslabljen i pojačan za 3% ... 119
Tablica 63 Zeleni kanal oslabljen i pojačan za 3%. ... 120
Tablica 64 Plavi kanal oslabljen i pojačan za 3%. ... 121
Tablica 65 Tablica boja s izračunatim vrijednostima svih varijacija kroz sve kanale ukupno za sve boje ... 123
Tablica 66 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan crveni kanal ... 125
Tablica 67 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan crveni kanal ... 126
Tablica 68 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan zeleni kanal ... 127
Tablica 69 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan zeleni kanal ... 128
Tablica 70 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za oslabljivan plavi kanal ... 129
Tablica 71 Tablica boja s izmjerenim L*a*b* vrijednostima te pripadajućim vrijednostima izračunate razlike boja ΔE_{00} za pojačavan plavi kanal ... 130

8. ŽIVOTOPIS

Ivana Pavlović je rođena 1981. godine u Zagrebu. Nakon završene osnovne škole u Samoboru, upisuje V. gimnaziju u Zagrebu na kojoj maturira 1999. godine. Iste godine upisuje Grafički fakultet Sveučilišta u Zagrebu, smjer Dizajn grafičkih proizvoda.

Tijekom studija je bila zaposlena kao demonstrator na kolegiju Grafičke tehnike u sklopu Katedre za likovnu kulturu i grafički dizajn (tijekom akademske godine 2002./2003.) te na Katedri za primijenjenu i umjetničku fotografiju (kolegiji Kreacija fotografijom 1, 2, Primijenjena fotografija 1, 2, Umjetnička fotografija 1, 2 - od akademske godine 2001./2002. do akademske godine 2006./2007.). Diplomirala je 2007. g. na Katedri za primijenjenu i umjetničku fotografiju. Od akademske godine 2007./2008. kao asistent u naslovnom zvanju radi na Katedri za primijenjenu i umjetničku fotografiju te na Katedri za fotografske procese. Od 2015. godine zaposlena je na Grafičkom fakultetu na Katedri za grafički dizajn i slikovne informacije, na kolegijima iz fotografija. Bila je istraživačica na dva projekta sufinancirana od Ministarstva znanosti, obrazovanja i športa Republike Hrvatske. Na projektu pod nazivom „Nove formulacije materijala, karakteristike otisaka i čimbenici okoliša“ (šifra projekta: 128-1281955-1953) čiji voditelj projekta je bila prof. Ivana Bolanča Mirković bila je od 1.2.2008.g. do završetka projekta, a na projektu pod nazivom „Evaluacija kvantitativnih i kvalitativnih kriterija procesa grafičke reprodukcije“ (šifra projekta: 128-1281955-1960) čiji voditelj je bio prof. Nikola Mrvac bila je od 2.1.2008.g. do kraja projekta. Od 2021.g. je aktivni istraživač na međunarodnom znanstveno istraživačkom projektu „Joint Croatia-China R&D project: Research and Application Demonstration an key Technologies of AR Information Service in Museum Based on 4G/5G“, čiji je voditelj projekta prof. Klaudio Pap.

Autorica je preko 70 stručnih i znanstvenih radova s područja fotografije, grafičke tehnologije i dizajna koji su objavljeni u znanstvenim i stručnim zbornicima radova te znanstvenim knjigama u Hrvatskoj i inozemstvu. Sudjelovala je na više domaćih i inozemnih stručnih i znanstvenih simpozija (Hrvatska, Slovenija, Njemačka, Slovačka). Kao autorica popularnih tekstova o fotografiji surađivala je s časopisom Grafička revija.

Sudjelovala je u vođenju tečajeva i seminara vezanih uz fotografiju u organizaciji Studentskog zbora, Grafičkog fakulteta, Samoborskog muzeja i Javne ustanove za upravljanje zaštićenim područjima i drugim zaštićenim vrijednostima na području Zagrebačke županije. Svojim je fotografijama ilustrirala kalendare, kataloge, razglednice, web stranice, plakate, omote CD-a i

sl. Sa Samoborskim muzejom surađivala je na digitalizaciji i restauraciji povijesnih fotografija te je bila voditeljica projekta 'Interaktivno upoznavanje Samobora kroz fotografiju'. Također je surađivala s grafičkim studiom Miš, studiom za dizajn Expositus i studiom za grafičko oblikovanje i ilustraciju TOjeNARA u području fotografije, crtane ilustracije, dizajna i preloma kataloga i knjiga te sa studiom Formula film za filmsku i video produkciju dizajnirajući knjige snimanja te brojnim drugim. Fotografijama i crtežima oslikava odjevne predmete te je dobitnica nagrade Parka prirode Žumberak – Samoborsko gorje u tom području.

Sudjelovala je u osnivanju i operacionalizaciji ljetnih škola i tečajeva. Na Grafičkom fakultetu vodila je stručni seminar Digitalna fotografija u području grafičkog dizajna i tehnologije 2006. godine. 2010. godine organizirala je radionicu lomografije – Lomography Hrvatska u sklopu međunarodne znanstvene konferencije Blaž Baromić - PDC Conference u Senju. Iste godine sudjelovala je u seminaru Snimanje digitalnim fotografskim aparatom, obrada i realizacija digitalnog zapisa fotografske slike – stručno usavršavanje nastavnika u srednjim strukovnim školama sektora Grafička tehnologija i audiovizualne tehnologije - Agencije za strukovno obrazovanje i obrazovanje odraslih u Zagrebu. Od 2011. do 2019. godine sudjelovala je u organizaciji tečajeva/ljetnih škola u sklopu međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić – PDC Conference pod nazivom „From light to lighting – Kreativno korištenje rasvjete“.

Bila je članica organizacijskog odbora projekta Modni ormar (u organizaciji Tekstilno-tehnološkog fakulteta Sveučilišta u Zagrebu) od 2006. do 2009. godine te je bila članica stručnog žiria za izbor najbolje modne fotografije od pokretanja Modnog ormara. Također je bila članica žiria za izbor najbolje fotografije fotografskog natječaja za mlade pod nazivom „Život je lijep“ u organizaciji Foto kluba Rijeka 2015. godine. Članica je žiria za Natječaj za fotografiju PDC (od 2010.g. -). Članica je žiria za Natječaj za fotografiju Inspiracija materijalom (od 2014. g. -).

Sudjelovala je u TV emisiji za prilog Modni ormar 2010. godine. Zatim je sudjelovala u HRT TV emisiji Znanstveni krugovi za prilog o fotografiji 2012 godine, a 2016. godine u TV prilogu za National Geographic India o događanju Khumba Mela Ujjain 2016.

Fotografije je izlagala na više samostalnih i skupnih izložbi prema popisu kako slijedi:

1. **Ivana Pavlović,** Ivan Tibor Grujić, Samoborke kroz muški i ženski objektiv, Samoborski muzej, Samobor, Hrvatska, 2018.
2. **Ivana Pavlović**, Tina Sirotić, Svibor Jančić, Himalaja – Gdje oblaci prenose poruke, Gradski muzej Vukovar, Vukovar, Hrvatska, 2017.

3. **Ivana Pavlović**, Tina Sirotić, Svibor Jančić, Himalaja – Gdje oblaci prenose poruke, Zorin dom, Karlovac, Hrvatska, 2017.
4. **Ivana Pavlović**, Tina Sirotić, Svibor Jančić, Himalaja – Gdje oblaci prenose poruke, Galerija Badrov, Zagreb, Hrvatska, 2016.
5. Nevenka Miklenić, **Ivana Pavlović**, Željko Nemec, Imre Kiss i Gabriella Jerszi: Tarski kaleidoskop, Mala dvorana Galerije Prica, Samobor, Hrvatska, 2015.
6. **Ivana Pavlović**, More vječnosti / Hommage Vesni Prica - Crvena haljina, Mala dvorana Galerije Prica, Samobor, Hrvatska, 2015.
7. 36 Zagreb salon, Muzej Mimara, (skupna izložba) Zagreb, Hrvatska, 2014.
8. Triennale autoportreta, Galerija Prica, (skupna izložba) Samobor, Hrvatska, 2014.
9. Treći element – Voda, Galerija Principij, (skupna izložba) Rijeka, Hrvatska, 2014.
10. Library thoughts 4, Hegyvidek Gallery, (skupna izložba) Budimpešta, Mađarska, 2014.
11. Photo Annual Awards, 2014., Teplice, Wall Gallery, (skupna izložba) Češka, 2014.
12. Fotografkinje 2014., Galerija Principij, (skupna izložba) Rijeka, Hrvatska, 2014.
13. Photodistorzija, Galerija Zuccato, Istarska sabornica, biennalna izložba fotografija, (skupna izložba) Poreč, Hrvatska; 2014.
14. CroArtPhoto Club međunarodni salon fotografije 2013. KRETANJE – MOTION, Cro Art Photo Club, (skupna izložba) Zagreb, Hrvatska; 11. mj. 2013.
15. IV WATER AND LIFE INTERNATIONAL ART BIENNALE, (skupna izložba) Baja, Mađarska, 2013.
16. Foto Ex Tempore – Novigrad, Anomalija, (skupna izložba) Hrvatska, 2013.
17. Aktovi., Cro Art Photo Club, (skupna izložba), Zagreb, Hrvatska, 2012.
18. **Ivana Pavlović**, Rijeka Sava - priroda, ljudi i kultura, Kulturni centar Gradiška, (skupna izložba) Gradiška, Bosna i Hercegovina, 2012.
19. **Pavlović, Ivana** Portreti s Bitke kod Samobora, Samoborski muzej, Samobor, 2012..
20. **Ivana Pavlović**, Portreti s Noći muzeja, Samoborski muzej, (samostalna izložba fotografija), Samobor, Hrvatska, 2011.
21. **Ivana Pavlović**, Akvareli na skeli - portreti umjetnika, (samostalna izložba fotografija), Posavski muzej Brežice, Brežice, Slovenija, 2011.
22. Pavlović, Ivana; Mikota, Miroslav Izložba fotografija povodom predstavljanja replike prve tiskarske preše u Hrvatskoj., 2011. (podatak o recenziji nije dostupan, izložba).
23. **Ivana Pavlović**, Rijeka Sava - priroda, ljudi i kultura, skupna izložba fotografija, Kulturni centar Gradiška, (skupna izložba) Gradiška, Bosna i Hercegovina, 2010.
24. **Ivana Pavlović**, Miroslav Mikota, Početci tiskarstva u Hrvatskoj, Senj, 2010.

25. **Ivana Pavlović**, Miroslav Mikota (odabir motiva akademkinja Anica Nazor), Baromićev Brevijar, Gradska Knjižnica, Senj, 2009.
26. **Ivana Pavlović**, Bakho - Grožđe, skupna izložba fotografija velikog formata (135 x 200 cm) u sklopu manifestacije "Bakhov ples", Buje, 2008.
27. **Ivana Pavlović**, Miroslav Mikota: 500. godina tiskanja knjiga u Senju (odabir motiva akademkinja Anica Nazor), Split, 2008.
28. **Ivana Pavlović**, Miroslav Mikota, Zadranin Šimun Kožičić i njegova glagoljaška tiskara (odabir motiva akademkinja Anica Nazor), Zadar, 2007.
29. **Ivana Pavlović**, 6. LUF - Labin u umjetničkoj fotografiji (skupna izložba), Galerija Alvona, Labin, 2006.
30. Miroslav Mikota, **Ivana Pavlović**: Izdanja senjske glagoljske tiskare (1494. - 1508.) Editions printed in glagolic printing house in Senj (1494. - 1508.) (odabir motiva akademkinja Anica Nazor), Novi Vinodolski, 2006.
31. Miroslav Mikota, **Ivana Pavlović**: Glagoljaška tiskara u Senju • Glagolic Printing House in Senj (odabir motiva akademkinja Anica Nazor), Lovran, 2005.
32. **Ivana Pavlović**, Izložba u sklopu multimedijalnog projekta vezanog uz proslavu godišnjice Grafomanije (suautor), Klub Pauk, Zagreb, 2003
33. **Ivana Pavlović**, Samobor by night, Klub studenata Istre, (samostalna izložba fotografija) Ilica 13/1, Zagreb, 2003.
34. **Ivana Pavlović**, Zvučni portreti, Klub studenata Istre, (samostalna izložba fotografija)Ilica 13/1, Zagreb, 2002.
35. Izložba odabranih radova studenata Grafičkog fakulteta - grafike (skupna izložba), izložbeni prostor Grafičkog fakulteta, Zagreb, 2002.
36. Izložba povodom izlaska studentskih novina Grafomanija (skupna izložba), Klub Tom-Tom, Zagreb, 2002.

Osvojila je više domaćih i stranih nagrada i priznanja među kojima se ističu: 3. mjesto za fotografiju na Natječaju Fotografkinje, Rijeka, Hrvatska, 2014. godine; počasno priznanje za fotografiju na Photo Annual Awards natječaju, Češka, 2014. godine; FIAP ribbon i diploma Fotokluba Zagreb za seriju fotografija na 36 Zagreb salonu, Hrvatska 2014. godine; diploma za seriju fotografija na Natječaju Treći element - voda, Hrvatska, 2014. godine.

Članica je Hrvatskog dizajnerskog društva i Hrvatskog društva grafičara.

8.1. Popis objavljenih radova

1. Brozović, Maja; Mikota, Miroslav; Pavlović, Ivana
   STEADFASTNESS OF COLOURS OF OUTDOOR ADVERTISING MEDIA. // STEADFASTNESS OF COLOURS OF OUTDOOR ADVERTISING MEDIA / Branko Katalinic (ur.).
   Beč: DAAAM International Vienna, 2010. str. 19-27

2. Mikota, Miroslav; Pavlović, Ivana
   ISO SPEED AS THE TECHNICAL AND CREATIVE ELEMENT OF THE DIGITAL PORTRAIT PHOTOGRAPHS. // DAAAM INTERNATIONAL SCIENTIFIC BOOK 2010 / Branko Katalinic (ur.).
   Beč: DAAAM International Vienna, 2010. str. 9-18

3. Mikota, Miroslav; Pavlović, Ivana; Brozović, Maja
   Influence of the Lighting on the Portrait Photographs Shot with the Digital Photography System. // DAAAM International Scientific Book 2008 / Katalinic, Branko (ur.).
   Vienna: DAAAM International Vienna, 2008. str. 463-476

4. Skala, Tibor; Mrvac, Nikola; Mikota, Miroslav; Pavlović, Ivana,
   Multimedia Image Rendering on a Distribued Computer System. // DAAAM International Scientific Book 2008 / Katalinic, Branko (ur.).
   Vienna: DAAAM International, 2008. str. 781-788. (https://www.bib.irb.hr/396552)

5. Mikota, Miroslav; Mitović Kukoč, Branka; Pavlović, Ivana
   Comparison of Ink Jet Gallery Art Photography Prints. // Graphic Arts: Technology, Design, Communications - Scientific Book 2006 / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
   Zagreb: University of Zagreb, Faculty of Graphic Arts ; Ogranak Matice hrvatske Senj ; Pulp and Paper Institute, Ljubljana, 2006. str. 51-62

6. Mikota, Miroslav; Pavlović, Ivana; Jecić, Zdenko
   Digital Photography Techniques in Area of Applied and Art Photography. // Graphic Arts: Technology, Design, Communications - Scientific Book 2006 / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
   Zagreb: University of Zagreb, Faculty of Graphic Arts ; Ogranak Matice hrvatske Senj ; Pulp and Paper Institute, Ljubljana, 2006. str. 27-42

7. Mikota, Miroslav; Pavlović, Ivana; Momčilović, Ana
   Semantic and syntax of ecologically engaged photography. // Graphic arts : technology, design, communications scientific book 2005 / Bolanca, Zdenka ; Mikota, Miroslav (ur.).
   Zagreb, Senj, Ljubljana: Grafički fakultet ; Matica hrvatska, Ogranak : Pulps and Paper Institute, 2005. str. 23-36

8. Mikota, Miroslav; Matijević, Mile; Pavlović, Ivana
   Colour reproduction analysis of portrait photography in cross-media system: image on the computer monitor–electrophotographic printing. // Imaging science journal, 64 (2016), 6; 299-304 doi:10.1080/13682199.2016.1184875 (međunarodna recenzija,

članak, znanstveni)

9. Mikota, Miroslav; Pavlović, Ivana; Matijević, Mile
   Effect of the changes in the RGB digital image channel on the perception of fashion photography while retaining its iconicity. // Tekstil : časopis za tekstilnu tehnologiju i konfekciju, 64 (2015), 1-2; 19-24 (međunarodna recenzija, članak, znanstveni)

10. Mikota, Miroslav; Matijević, Mile; Pavlović, Ivana
    REALIZACIJA HDR FOTOGRAFIJE Hi Fi DOD BUBBLE JET ISPISOM NA OPTIMALNOJ PODLOZI ZA ISPIS. // Tehnički Glasnik: Znanstveno-stručni časopis Veleučilišta u Varaždinu, 7 (2013), 3; 252-257 (podatak o recenziji nije dostupan, prethodno priopćenje, znanstveni)

11. Mikota, Miroslav; Brozović, Maja; Pavlović, Ivana
    Kvaliteta fotografske prezentacije modnih noviteta u medijima vanjskog oglašavanja. // Tekstil: časopis za tekstilnu tehnologiju i konfekciju, 57 (2008), 9; 457-464 (međunarodna recenzija, članak, znanstveni)

12. Verzak, Željko; Oreški, Iva; Pavlović, Ivana; Modrić, Vesna Erika; Karlović, Zoran; Brcković, Monika
    Primjena lokalnih anestetika u pedodonciji. // Medix : specijalizirani medicinski dvomjesečnik, 22 (2016), 119/120; 236-240 (podatak o recenziji nije dostupan, članak, stručni)

13. Verzak, Željko; Pavlović, Ivana; Petković, Anja; Oreč, Ivona; Karlović, Pjetra; Brcković, Monika; Modrić, Vesna Erika
    Hitna stanja u stomatološkoj ordinaciji. // Medix : specijalizirani medicinski dvomjesečnik, 21 (2015), 118; 1-4 (podatak o recenziji nije dostupan, članak, stručni)

14. Pavlović, Ivana; Mikota, Miroslav; Ptiček, Petra
    UTJECAJ MALIH PROMJENA VRIJEDNOSTI KANALA ZAPISA NA PERCEPCIJU PORTRETNE FOTOGRAFSKE SLIKE. // Proceedings of 23rd international conference on printing, design and graphic communications Blaž Baromić 2019 / Mikota, Miroslav (ur.).
    Senj, Hrvatska, 2019. str. 48-52 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

15. Pavlović, Ivana; Žeželj, Teo; Mikota, Miroslav; Vlašić, Jelena
    Analiza manipulacije portretnom fotografskom slikom promjenama vrijednosti R kanala zapisa. // Proceedings of the 17th International Conference MATRIB 2016 / Žmak, Irena ; Aleksandrov Fabijanić, Tamara ; Ćorić, Danko (ur.).
    Zagreb: Hrvatsko društvo za materijale i tribologiju, 2016. str. 278-284 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

16. Miljković, Petar; Pavlović, Ivana; Mulović, Ana
    Računalni sustavi u funkciji modeliranja grafičke reprodukcije. // Proceedings of the 16th International Conference MATRIB 2015 / Ćorić, Danka ; Žmak, Irena (ur.).
    Zagreb: Hrvatsko društvo za materijale i tribologiju, 2015. str. 254-260 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

17. Pavlović, Ivana; Bogdanović, Siniša; Bosančić, Željko
SIMULACIJA PRIMJENE OBOJENIH FILTERA ZA CRNO- BIJELU FOTOGRAFIJU. // Proceedings of 18th international conference on printing, design and graphic communications Blaž Baromić 2014 ; Zbornik radova 18. međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić 2014 / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, Hrvatska, 2014. str. 318-327 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

18. Rastočić, Martina; Mikota, Miroslav; Pavlović, Ivana
Prepoznatljivost modne fotografije objavljene na društvenim mrežama. // Proceedings of 18th international conference on printing, design and graphic communications Blaž Baromić 2014 ; Zbornik radova 18. međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić 2014 / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, 2014. str. 306-317 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

19. Zrinščak, Irena; Mikota, Miroslav; Pavlović, Ivana
HRVATSKA FOTOGRAFIJA I FOTOAMATERI NAKON II. SVJETSKOG RATA. // Proceedings of 18th international conference on printing, design and graphic communications Blaž Baromić 2014 ; Zbornik radova 18. međunarodne konferencije tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić 2014 / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, Hrvatska, 2014. str. 365-383 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

20. Petrić, Korina; Mikota, Miroslav; Matijević, Mile; Pavlović, Ivana
Utjecaj promjene vrijednosti RGB kanala na percepciju fotografije voća. // Zbornik radova / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, 2013. str. 66-81 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

21. Mikota Miroslav; Pavlović, Ivana; Tomiša, Mario; Matijević, Mile
UTJECAJ IZBORA DOD Hi Fi BUBBLE JET PODLOGE ZA ISPIS NA STANDARDNE BOJE REALNIH FOTOGRAFSKIH MOTIVA. // Zbornik radova - International Conference MATRIB 2013 / Alar, Željko ; Jakovljević, Suzana ; Šolić, Sanja (ur.).
Zagreb: Hrvatsko društvo za materijale i tribologiju, 2013. str. 261-269 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

22. Dijan, Andrijana; Zjakić, Igor; Pavlović, Ivana; Mikota, Miroslav
EVALUACIJA ISPISA FOTOGRAFIJA ARHITEKTURE. // Zbornik radova - MATRIB 2013 / Alar, Željko ; Jakovljević, Suzana ; Šolić, Sanja (ur.).
Zagreb: Hrvatsko društvo za materijale i tribologiju, 2013. str. 101-110 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

23. Zrinščak, Irena; Mikota, Miroslav; Pavlović, Ivana
Početak zlatnog doba hrvatske fotografije. // Zbornik radova / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, 2013. str. 157-170 (predavanje, međunarodna

recenzija, cjeloviti rad (in extenso), znanstveni)

24. Maričević, Marko; Pavlović, Ivana; Mikota, Miroslav; Divjak, Alan
Analiza metoda forenzike digitalnog zapisa fotografije. // Tiskarstvo & design 2013 / Žiljak Vujić, Jana (ur.).
Zagreb: FS, 2013. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

25. Mikota, Miroslav; Pavlović, Ivana
UTJECAJ PRIMJENE POLARIZACIJSKOG FILTERA NA BOJE SNIMLJENE FOTOGRAFIJE. // Zbornik radova / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara,, 2012. str. 473-478 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

26. Pavlović, Ivana; Mikota, Miroslav
Formiranje moderne fotografije. // Zbornik radova / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, 2012. str. 337-347 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

27. Mikota, Miroslav; Pavlović, Ivana; Matijević, Mile; Milković, Marin
Utjecaj izbora tekstilne podloge na karakteristike ispisa fotografija realiziranih indirektnim Ink uz korištenje Jet ispisom termički aktivirajućeg mastera. // Proceedings MATRIB 2011 / Schauperl, Zdravko ; Šolić, Sanja (ur.).
Zagreb: Hrvatsko društvo za materijale i tehnologiju, 2011. str. 330-337 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

28. Pavlović, Ivana; Periša, Mario; Čut, Tomislav
Utjecaj osvjetljenja površine na kvalitetu reprodukcije boja u digitalnoj fotografiji. // Proceedings 15th International Conference on Printing, Design and Graphic Communications Blaž Baromić 2011 / Mikota, Miroslav (ur.).
Zagreb: HDG, 2011. str. 458-476 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

29. Mikota, Miroslav; Pavlović, Ivana; Kozina, Goran; Tomiša, Mario
DORADA PODLOGE ZA ISPIS KAO MODULATOR CESIE I DOŽIVLJAJA BOJA FOTOGRAFIJA REALIZIRANIH Hi Fi BUBBLE JET ISPISOM. // ZBORNIK RADOVA - CONFERENCE PROCEEDINGS MATRIB 2011 / Schauperl, Zdravko ; Šolić, Sanja (ur.).
Zagreb: Hrvatsko društvo za materijale i tribologiju, 2011. str. 338-345 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

30. Mikota, Miroslav; Pavlović, Ivana; Kajganović, Jelena
UTJECAJ PROMJENA NA RGB KANALIMA NA PERCEPCIJU I PRIHVATLJIVOST PORTRETNE FOTOGRAFIJE. // Proceedings 15th International Conference on Printing, Design and Graphic Communications Blaž Baromić 2011 / Mikota, Miroslav (ur.).
Zagreb: 978-953-56838-1-0, 2011. str. 412-419 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

31. Modrić, Damir; Pavlović, Ivana; Mikota, Miroslav
Analiza glagoljičkih knjiga temeljena na fotografskoj digitalizaciji. // Proceedings 15th International Conference on Printing, Design and Graphic Communications Blaž Baromić 2011 / / Mikota, Miroslav (ur.).
Zagreb: HDG, 2011. str. 80-87 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

32. Modrić, Damir; Pavlović, Ivana; Mikota, Miroslav
Analiza glagoljičkih knjiga temeljena na fotografskoj digitalizaciji. // ZBORNIK RADOVA / Mikota, Miroslav (ur.).
Zagreb: Hrvatsko društvo grafičara, 2011. str. 80-87 (ostalo, domaća recenzija, cjeloviti rad (in extenso), znanstveni)

33. Pavlović, Ivana; Mikota, Miroslav; Matijević, Mile; Mrvac, Nikola
ANALYZES OF THE CHANGES ON THE PHOTOGRAPHIC ILLUSTRATION REALIZED THROUGH ELECTROPHOTOGRAPHIC PRINTING. // Proceedings of 5th International Symposium on Novelties in Graphics / Simončič, Barbara ; Hladnik, Aleš ; Pavko - Čuden, Alenka ; Ahtik, Jure ; Luštek, Barbara ; Demšar, Andrej ; Urbas, Raša (ur.).
Ljubljana: Univerza Ljubljana, 2010. str. 786-790 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

34. Mikota, Miroslav; Pavlović, Ivana
Skin Colour Changes in the System: Flashlight Shooting-Editing-Sublimation Printing. // Annals of DAAAAM for 2009 and Proceedings of the 20th DAAAAM Symposium "Inteligent Manifacturing & Automation : Focus on Theory, Practice and Education" / Katalinić, Branko (ur.).
Vienna: DAAAAM International, 2009. str. 1283-1284 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

35. Mikota, Miroslav; Pavlović, Ivana
IMPACT OF RENDERING WITH PERCEPTUAL INTENTS ON COLORIMETRIC VALUES AND IMPRESSION OF PORTRAIT PHOTOGRAPHS. // 13th INTERNATIONAL CONFERENCE ON PRINTING, DESIGN AND GRAPHIC COMMUNICATIONS - PROCEEDINGS / Bolanča, Zdenka (ur.).
Zagreb: University of Zagreb, Faculty of Graphic Arts, Croatia ; University of Ljubljana, Faculty of Natural Science and Engineering, Slovenia ; Ogranak Matice hrvatske Senj, Croatia ; Pulp and Paper Institute, Ljubljana, Slovenia, 2009. str. 101-104. (https://www.bib.irb.hr/464211) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

36. Matijević, Mile; Mrvac, Nikola; Milković, Marin; Pavlović, Ivana; Mikota, Miroslav
Evaluation of the Perception of Stimulus Contrast in Light Tones of Additive Synthesis. // Annals of DAAM for 2009 & proceedings of the 20th International DAAAM Symposium : Intelligent Manufactoring & Automation : focus on theory, practice and education / Katalinić, Branko (ur.).
Vienna: DAAAM International, 2009. str. 1863-1864 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

37. Pavlović, Ivana; Mikota, Miroslav
19th CENTURY PHOTOGRAPHY WORLDWIDE AND IN CROATIA. // 13th INTERNATIONAL CONFERENCE ON PRINTING, DESIGN AND GRAPHIC COMMUNICATIONS - PROCEEDINGS / Bolanča, Zdenka (ur.).
Zagreb: Zagreb : University of Zagreb, Faculty of Graphic Arts, Croatia ; University of Ljubljana, Faculty of Natural Science and Engineering, Slovenia ; Ogranak Matice hrvatske Senj, Croatia ; Pulp and Paper Institute, Ljubljana, Slovenia, 2009. str. 129-133. (https://www.bib.irb.hr/464244) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

38. Pavlović, Ivana; Mikota, Miroslav; Mrvac, Nikola
Exposure Correction in Digital Portrait Photography Taken with the Nitraphot Lighting. // DAAAAM Symposium "Inteligent Manifacturing & Automation : Focus on Theory, Practice and Education" / Katalinić, Branko (ur.).
Vienna: DAAAAM International, 2009. str. 1449-1450 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

39. Božić, Tomica; Matijević, Mile; Mrvac, Nikola; Pavlović, Ivana
Changes in the company multimedia environment. // 13th International Conference of Printing, Design and Graphic Communication "Blaž Baromić 09" : proceedings / Bolanča, Zdenka (ur.).
Zagreb ; Ljubljana ; Senj: Faculty of Graphic Arts ; Faculty of Natural Science and Engineering ; Pulp and Paper Institute ; Matica hrvatska, Ogranak, 2009. str. 201-204 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

40. Mikota, Miroslav; Pavlović, Ivana; Mrvac, Nikola
Influence of the printing technique on the quality of the digitally shot colour portrait. // Proceedings, 19th International DAAAM Symposium: Intelligent Manufacturing & Automation: "Focus on Next Generation of Intelligent Systems and Solutions" / Katalinić, Branko (ur.).
Vienna: DAAAM International, 2008. str. 863-864 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

41. Mikota, Miroslav; Pavlović, Ivana; Kulčar, Rahela
Influence of redefining the color space on the complete impression of digital portrait photograph shot with apropriate white balance. // 12th International conference of printing, design and graphic communication Blaž Baromić : Proceedings / Bolanča, Zdenka (ur.).
Zagreb ; Ljubljana ; Senj: Faculty of graphic arts ; Pulps and Paper Institute ; Matica hrvatska, Ogranak, 2008. str. 149-153 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

42. Mikota, Miroslav; Pavlović, Ivana; Jurković, Mato
The Appearance and Development of the Portrait Photography in the 19th Century. // Proceedings of the 12th International conference of printing, design and graphic communications Blaž Baromić / Bolanča, Zdenka (ur.).
Zagreb ; Ljubljana ; Senj: aculty of Graphic Arts ; Faculty of natural science and engineering ; Pulp and paper institute ; Matica hrvatska, Ogranak, 2008. str. 143-147 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

43. Pavlović, Ivana; Mikota, Miroslav; Skala, Tibor
Influence of the Lighting and the ISO Speed on the Digitally Shot Black and White Portrait Phorographs. // Proceedings of the 19th International DAAAM Symposium Intelligent Manufacturing & Automation : Focus on Next Generation of Intelligent Systems and Solutions / Katalinić, Branko (ur.).
Vienna: DAAAM International, 2008. str. 1045-1046 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

44. Stupić, Marko; Pavlović, Ivana; Mikota, Miroslav
Color changes in system motive - digital photography - digital printing. // Printing future days 2007, Proceedings / Schuhmann, Conny ; Baumann, Reinhard R. (ur.). (ur.).
Chemnitz: Chemnitz University of Technology, 2007. str. 69-75 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

45. Mahović Poljaček, Sanja; Pavlović, Ivana; Gojo, Miroslav
Analysis of Colours under Different Illuminants. // Proceedings of the DESIGN 2006 / Žiljak, Vilko (ur.).
Zagreb: Faculty of Mechanical Engineering and Naval Architecture, Univesity of zagreb, 2006. str. 1575-1582 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

46. Mikota, Miroslav; Pavlović, Ivana; Jecić, Zdenko
CMY ispis digitalnih crno-bijelih fotografija. // 10. medjunarodno savjetovanje tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić / 10th international conference on printing, design and graphic communications : zbornik radova = Proceedings / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
Zagreb: Grafički fakultet Zagreb ; Ogranak Matice hrvatske Senj, 2006. str. 65-74 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

47. Mikota, Miroslav; Pavlović, Ivana; Kulčar, Rahela
Bubble jet printing of digital photography. // Book of proceedings of the 2nd International Symposium on Novelties in Graphics / Simončić, Barbara ; Možina, Klementina ; Jeler, Slava ; Demšar, Andrej (ur.).
Ljubljana: Faculty of Natural Sciences and Engineering, Department of Textiles, 2006. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

48. Mikota, Miroslav; Mitrović Kukoč, Branka; Pavlović, Ivana
Usporedba galerijskih piezoelektričnih ispisa umjetničke fotografije. // 9. međunarodno savjetovanje tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić : zbornik radova = proceedings / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
Zagreb ; Senj ; Ljubljana: Grafički fakultet ; Matica hrvatska, Ogranak ; Inštitut za celulozo in papir, 2005. str. 123-130 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

49. Mikota, Miroslav; Kukoč, Branka; Momčilović, Ana; Pavlović, Ivana
Utjecaj izbora fotografskog sustava na karakteristike fotografske ilustracije. // Zbornik radova 7. znanstveno-stručni simpozij hrvatskih grafičara Blaž Baromić : zbornik radova / Bolanča, Zdenka (ur.).
Zagreb ; Senj: Grafički fakultet ; Matica hrvatska, 2003. str. 209-214 (predavanje,

domaća recenzija, cjeloviti rad (in extenso), znanstveni)

50. Mikota, Miroslav; Matijević, Mile; Pavlović, Ivana
UTJECAJ KOLORIMETRIJSKIH VRIJEDNOSTI TISKOVNE PODLOGE NA ELEKTROFOTOGRAFSKU REPRODUKCIJU DIGITALNE PORTRETNE FOTOGRAFIJE. // ZBORNIK SAŽETAKA - CONFERENCE PROCEEDINGS MATRIB 2010 / Schauperl, Zdravko ; Šnajdar, Mateja (ur.).
Zagreb: Hrvatsko društvo za materijale i tribologiju, 2010. str. 314-318 (poster, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

51. Mikota, Miroslav; Pavlović, Ivana; Periša, Mario; Golubović, Kristijan
Utjecaj odabira podloge za ispis na karakteristike digitalne fotografije. // Zbornik radova - conference proceedings matrib 2009 / Grilec, Krešimir ; Marić, Gojko (ur.).
Zagreb: Hrvatsko društvo za materijale i tribologiju, 2009. str. 359-365 (poster, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

52. Mikota, Miroslav; Pavlović, Ivana
ANALIZA SEMANTIČKIH SVOJSTAVA FOTOGRAFIJA OBJAVLJENIH U TISKANIM MEDIJIMA I NA INTERNETU – USPOREDBA STANJA U HRVATSKOJ I SVIJETU. // Zbornik radova 2. Međunarodni simpozij 'Učinkovito djelovanje put u vrijeme znanja', Utjecaj znanja na ljudske vrijednosti / Kos, Igor (ur.).
Varaždin: Elektrostrojarska škola Varaždin, 2008. str. 68-70 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

53. Pavlović, Ivana; Knapić, Leo
Početci razvoja umjetničke fotografije. // 10. medjunarodno savjetovanje tiskarstva, dizajna i grafičkih komunikacija Blaž Baromić / 10th international conference on printing, design and graphic communications : zbornik radova = Proceedings / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
Zagreb: Grafički fakultet Zagreb ; Ogranak Matice hrvatske Senj, 2006. str. 43-48 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

54. Pavlović, Ivana; Kulčar, Rahela
Fotografija uz slabe svjetlosne uvjete. // 9. međunarodno savjetovanje tiskarstva, dizajna i grafičkih komunikacija : Zbornik radova = Proceedings / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
Zagreb ; Senj ; Ljubljana: Grafički fakultet Sveučilišta ; Ogranak Matice hrvatske ; Inštitut za celulozo in papir, 2005. str. 93-98 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

55. Preglej, Ivana; Pavlović, Ivana
Noćna fotografija. // 8. savjetovanje tiskarstva, dizajna i grafičkih komunikacija, Blaž Baromić 2004 - zbornik radova / Bolanča, Zdenka ; Mikota, Miroslav (ur.).
Zagreb: Grafički fakultet Zagreb ; Ogranak Matice hrvatske Senj, 2004. str. 101-106 (poster, domaća recenzija, cjeloviti rad (in extenso), stručni)

56. Pavlović, Ivana; Mikota, Miroslav
STEREOFOTOGRAFIJA. // Proceedings 15th International Conference on Printing, Design and Graphic Communications Blaž Baromić 2011 / Mikota, Miroslav (ur.).

Zagreb: HDG, 2011. str. 447-457 (poster, međunarodna recenzija, cjeloviti rad (in extenso), ostalo)

57. Pavlović, Ivana; Mikota, Miroslav; Ptiček, Petra; Žeželj, Teo
ISTRAŽIVANJA UTJECAJA MALIH PROMJENA VRIJEDNOSTI RGB KANALA NA FOTOGRAFSKU REPRODUKCIJU BOJE LJUDSKE KOŽE. // 20th International Conference on Materials MATRIB 2019 / Šolić, Sanja ; Schauperl, Zdravko ; Pugar, Daniel (ur.).
Vela Luka, Hrvatska, 2019. str. 246-246 (predavanje, međunarodna recenzija, sažetak, znanstveni)

58. Pavlović, Ivana; Ptiček, Petra; Artuković, Marinko; Mikota, Miroslav
PROMJENE BOJE KOŽE UZ ZADRŽAVANJE IKONIČNOSTI UPRAVLJANJEM G I B KANALIMA DIGITALNOG ZAPISA PORTRETNE FOTOGRAFSKE SLIKE. // PRINTING&DESIGN19 / Gršić Žiljak ; Jana (ur.).
Zagreb, Hrvatska, 2019. str. 33-33 (predavanje, međunarodna recenzija, sažetak, znanstveni)

59. Pavlović, Ivana; Mikota, Miroslav; Vusić, Damir
Tehnički i kreativni aspekti HDR fotografije. // Zbornik radova / Babić, Darko (ur.).
Travnik: Fakultet za tehničke studije Univerziteta u Travniku, BiH, 2016. 052016-10, 7 (predavanje, međunarodna recenzija, sažetak, stručni)

60. Pavlović, Ivana
Fotografski stilovi od početaka umjetničke fotografije do danas., 2007., diplomski rad, Grafički fakultet, Zagreb